



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ
ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

Πρόβλεψη Φωτοβολταϊκής Ισχύος με Federated Learning

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Λεωνίδας Γ. Σπυρόπουλος

Επιβλέπων : Μαρινάκης Ευάγγελος
Επίκουρος Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούνιος 2024



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ
ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

Federated Learning for Photovoltaic Power Forecasting

THESIS

Leonidas G. Spyropoulos

Supervisor: Marinakis Evangelos
NTUA Assistant Professor

Athens, June 2024



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ
ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

Federated Learning for Photovoltaic Power Forecasting

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Λεωνίδας Γ. Σπυρόπουλος

Επιβλέπων : Μαρινάκης Ευάγγελος
Επίκουρος Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 15^η Ιουλίου 2024.

.....
Μαρινάκης Ευάγγελος
Επίκουρος Καθηγητής Ε.Μ.Π.

.....
Ψαρράς Ιωάννης
Καθηγητής Ε.Μ.Π.

.....
Ασκούνης Δημήτριος
Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούνιος 2024

.....

Σπυρόπουλος Λεωνίδα

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

Copyright © Σπυρόπουλος Λεωνίδα, 2024.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Στην οικογένεια μου

Περίληψη

Στην παρούσα εργασία, διερευνώνται οι δυνατότητες του Federated Learning (FL) για την ενίσχυση της πρόβλεψης ισχύος φωτοβολταϊκών συστημάτων με διατήρηση της ιδιωτικότητας των δεδομένων. Η έρευνα υπογραμμίζει την επιτακτική ανάγκη για αποτελεσματικές και ασφαλείς μεθόδους πρόβλεψης της παραγωγής ηλιακής ενέργειας, δεδομένης της αυξανόμενης εξάρτησης από τις ανανεώσιμες πηγές ενέργειας και της ευαισθησίας των σχετικών δεδομένων. Τονίζεται η σημασία της ιδιωτικότητας στην πρόβλεψη ισχύος, καθώς πρέπει να προστατεύονται ευαίσθητα δεδομένα από διαφορετικά φωτοβολταϊκά συστήματα. Το Federated Learning προσφέρει μια πολλά υποσχόμενη λύση, επιτρέποντας την εκπαίδευση μοντέλων σε τοπικά δεδομένα χωρίς να απαιτείται ανταλλαγή δεδομένων, καθώς οι μέχρι τώρα συγκεντρωτικοί αλγόριθμοι πρόβλεψης βασίζονται στη συνάθροιση δεδομένων. Το FL διατηρεί την ιδιωτικότητα και συμμορφώνεται με τους κανονισμούς προστασίας δεδομένων. Αξιολογώντας προηγούμενες εφαρμογές και έρευνες στον FL, διαπιστώθηκε ότι ενώ το FL έχει εφαρμοστεί σε διάφορους τομείς, η χρήση του στην πρόβλεψη ισχύος φωτοβολταϊκών παραμένει ένας ανοικτός προς διερεύνηση τομέας με το υλικό να μην είναι απεριόριστο. Στο παρόν έργο συγκρίνονται έξι (6) διαφορετικές στρατηγικές FL (FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi) χρησιμοποιώντας ένα μοντέλο LSTM για την πρόβλεψη ισχύος των φωτοβολταϊκών συστημάτων. Η εφαρμογή αυτών των στρατηγικών σε δεδομένα από επτά (7) φωτοβολταϊκά συστήματα σε διαφορετικές τοποθεσίες παρείχε ένα ισχυρό πλαίσιο για ανάλυση. Χρησιμοποιώντας μετρικές αξιολόγησης όπως RMSE, nRMSE, MBE και R^2 , πραγματοποιήθηκε μια ολοκληρωμένη αξιολόγηση των επιδόσεων. Τα αποτελέσματα έδειξαν ότι οι στρατηγικές FL μπορούν να προβλέψουν αποτελεσματικά την ισχύ των φωτοβολταϊκών συστημάτων, διατηρώντας παράλληλα το απόρρητο των δεδομένων. Κάθε στρατηγική έδειξε διαφορετικά επίπεδα ακρίβειας και ευρωστίας, με ορισμένες στρατηγικές να αποδίδουν καλύτερα.

Λέξεις Κλειδιά: Πρόβλεψη Φωτοβολταϊκής Ισχύος, Μηχανική Μάθηση, Τεχνητά Νευρωνικά Δίκτυα (ANN), Δίκτυα Μακράς Βραχυπρόθεσμης Μνήμης (LSTM), Federated Learning.

Abstract

In this paper, we investigate the potential of Federated Learning (FL) for enhancing PV power prediction while maintaining data privacy. The research highlights the urgent need for efficient and secure methods to predict solar power generation, given the increasing dependence on renewable energy sources and the sensitivity of the associated data. The importance of privacy in power forecasting is emphasised, as sensitive data from different PV systems must be protected. Federated Learning offers a promising solution, enabling model training on local data without requiring data exchange, as the previously centralized forecasting algorithms rely on data aggregation. FL maintains privacy and complies with data protection regulations. Evaluating previous applications and research in FL, it was found that while FL has been applied in various fields, its use in PV power forecasting remains an open area to be explored with the literature not being unlimited. In this project, six (6) different FL strategies (FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam and FedYogi) are compared using an LSTM model for power forecasting of PV systems. Applying these strategies to data from seven (7) PV systems at different locations provided a robust framework for analysis. Using evaluation metrics such as RMSE, nRMSE, MBE and R^2 , a comprehensive performance evaluation was performed. The results showed that FL strategies can effectively predict the performance of PV systems while maintaining data confidentiality. Each strategy demonstrated different levels of accuracy and robustness, with certain strategies performing better.

Keywords: Photovoltaic Power Forecasting, Machine Learning, Artificial Neural Networks (ANN), Long Short-Term Memory Networks (LSTM), Federated Learning.

Περιεχόμενα

1	Εισαγωγή	20
1.1	Φωτοβολταϊκά Συστήματα	20
1.1.1	Ηλιακή Ενέργεια και Φωτοβολταϊκά Συστήματα.....	20
1.1.2	Προκλήσεις στην Ενσωμάτωση Φωτοβολταϊκών Συστημάτων.....	20
1.2	Πρόβλεψη Παραγωγής Ισχύος.....	21
1.2.1	Μέθοδοι Πρόβλεψης Παραγωγής Ενέργειας	21
1.2.2	Νευρωνικά Δίκτυα στην Πρόβλεψη Ισχύος.....	22
1.2.3	Ζητήματα Προστασίας Προσωπικών Δεδομένων	22
1.3	Federated Learning (FL).....	22
1.3.1	Εισαγωγή στο Federated Learning.....	22
1.3.2	Προκλήσεις στο Federated Learning	24
1.4	Έρευνες και Περιορισμοί στην Πρόβλεψη Φωτοβολταϊκής Ισχύος.....	24
1.5	Συνεισφορές της Παρούσας Εργασίας	26
1.6	Δομή του Υπόλοιπου Εγγράφου	26
2	Θεωρητικό Υπόβαθρο	27
2.1	Χρονικοί Ορίζοντες PV Power Forecasting	27
2.1.1	Βραχυπρόθεσμη Πρόβλεψη (Short-Term Forecasting)	27
2.1.2	Μεσοπρόθεσμη Πρόβλεψη (Medium-Term Forecasting).....	27
2.1.3	Μακροπρόθεσμη Πρόβλεψη (Long-Term Forecasting)	28
2.2	Μέθοδοι PV Power Forecasting και ANN	28
2.2.1	Φυσικές Μέθοδοι (Physical Methods)	28
2.2.2	Στατιστικές Μέθοδοι (Statistical Methods).....	29
2.2.3	Μέθοδοι Τεχνητών Νευρωνικών Δικτύων(Artificial Neural Networks (ANN) methods)	29
2.3	Federated Learning.....	32
2.3.1	Εισαγωγή στο Federated Learning.....	32
2.3.2	Εφαρμογές του Federated Learning σε Ενεργειακά Συστήματα.....	33
2.3.3	Προκλήσεις και Ερευνητική Προσέγγιση	34
2.4	Ιστορία και Σχεδιασμός του LSTM Μοντέλου	34
2.4.1	Ορισμός του Long Short-Term Memory (LSTM) και Ιστορική Αναδρομή	34
2.4.2	Βασικές Αρχές και Λειτουργία του LSTM	35
3	Σχετικές Έρευνες	39
3.1	Βραχυπρόθεσμη Πρόβλεψη Φωτοβολταϊκής Ισχύος.....	39
3.1.1	Παραδοσιακές Μέθοδοι	39

3.1.2	Μέθοδοι Μηχανικής Μάθησης.....	40
3.2	Federated Learning.....	40
3.2.1	Εφαρμογές στον Ενεργειακό Τομέα	40
3.2.2	Εφαρμογές στην Πρόβλεψη Φωτοβολταϊκής Ισχύος	40
3.3	Ευρήματα Ανασκόπησης των Σχετικών Ερευνών	41
4	Παρουσίαση Εργαλείων και Συνόλου Δεδομένων	42
4.1	Παρουσίαση και Ανάλυση Εργαλείων που Χρησιμοποιήθηκαν	42
4.1.1	Γλώσσα Προγραμματισμού Python.....	42
4.1.2	Pytorch.....	42
4.1.3	Βιβλιοθήκες Pandas, NumPy, Scikit-learn και Matplotlib.....	43
4.1.4	Visual Studio Code (VS Code).....	45
4.1.5	Flower A Friendly Federated Learning Framework	45
4.1.6	Συμπεράσματα	46
4.1.7	Εκδόσεις εργαλείων και τεχνικά χαρακτηριστικά υπολογιστή	47
4.2	Περιγραφή Συνόλου Δεδομένων	47
4.2.1	Φωτοβολταϊκά Συστήματα	48
4.2.2	Δεδομένα Φωτοβολταϊκών	49
4.2.3	Διαίρεση Συνόλου Δεδομένων	51
5	Μεθοδολογία και Ανάπτυξη Αλγορίθμου	53
5.1	Μαθηματικός Χειρισμός Δεδομένων	53
5.2	Federated Learning Framework.....	54
5.2.1	Federated Learning.....	54
5.2.2	Μαθηματική Ανάλυση	55
5.2.3	Αναλυτική Επεξήγηση Federated Learning (FL) Framework.....	56
5.2.4	Προβλήματα	60
5.2.5	Αλγόριθμος.....	62
5.2.6	Ψευδοκώδικας αλγορίθμου Federated Learning.....	65
5.2.7	Διαγράμματα Ροής	71
5.3	Παρουσίαση και Ανάλυση Στρατηγικών Federated Learning	74
6	Αξιολόγηση Αποτελεσμάτων	80
6.1	Μετρικές Αξιολόγησης (Evaluation Metrics).....	80
6.1.1	Root Mean Square Error (RMSE).....	80
6.1.2	Normalized Root Mean Square Error (nRMSE).....	81
6.1.3	Mean Bias Error (MBE)	81
6.1.4	Coefficient of Determination (R^2).....	81
6.1.5	Συμπεράσματα	82

6.2	Αποτελέσματα Προσομοίωσης και Πειραμάτων.....	82
6.2.1	Γενική Ανασκόπηση.....	84
6.2.2	Ανάλυση ανά Φωτοβολταϊκό Σύστημα.....	86
6.3	Συμπεράσματα Αποτελεσμάτων	97
7	Συμπεράσματα και Προτάσεις Μελλοντικής Εξέλιξης.....	98
7.1	Συμπεράσματα	98
7.2	Προτάσεις Μελλοντικής Εξέλιξης.....	99
8	Βιβλιογραφία	101

Λίστα Εκθεμάτων

Εικόνα 1: Fossil fuel capacity from IEA (2022), World Energy Outlook 2022.....	21
Εικόνα 2: Model weights exchange between the central server and the clients in a Federated Learning system.....	33
Εικόνα 3: The Long Short-Term Memory (LSTM) Cell Structure.....	38
Εικόνα 4: The Long Short-Term Memory (LSTM) Model Architecture.....	38
Εικόνα 5: Map with the locations of the PV facilities.....	49
Εικόνα 6: Map of the city of Lisbon with the locations of four PV facilities.....	49
Εικόνα 7: PV data aggregation method and training inside a Federated Learning Architecture.....	56
Εικόνα 8: Overview of the Federated Learning Framework for PV Power Forecasting.....	57
Εικόνα 9: Illustration of the process of a Federated Learning framework.....	60
Εικόνα 10: Pseudocode of the Initialization of the Federated Learning process.....	65
Εικόνα 11: Pseudocode of the Client Setup of the Federated Learning process.....	66
Εικόνα 12: Pseudocode of the Model Architecture Setup of the Federated Learning process.....	67
Εικόνα 13: Pseudocode of the Training procedure of the Federated Learning process.....	68
Εικόνα 14: Pseudocode of the Aggregation procedure of the Federated Learning process.....	69
Εικόνα 15: Pseudocode of the Evaluation procedure of the Federated Learning process.....	69
Εικόνα 16: Pseudocode of the Iteration procedure of the Federated Learning process.....	70
Εικόνα 17: Pseudocode of the Termination of the Federated Learning process.....	70
Εικόνα 18: Flower Client Implementation.....	71
Εικόνα 19: Data Preperation to Create DataLoaders.....	72
Εικόνα 20: Procedure of Evaluation and Start of Simulation.....	73
Εικόνα 21: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₁ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi.....	86
Εικόνα 22: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₁ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi.....	87
Εικόνα 23: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₂ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi.....	88
Εικόνα 24: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₂ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi.....	88
Εικόνα 25: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₃ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi.....	89
Εικόνα 26: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₃ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi.....	90

Εικόνα 27: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₄ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi	91
Εικόνα 28: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₄ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi	91
Εικόνα 29: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₅ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi	92
Εικόνα 30: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₅ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi	93
Εικόνα 31: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₆ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi	94
Εικόνα 32: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₆ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi	94
Εικόνα 33: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₇ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi	95
Εικόνα 34: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV ₇ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi	96

Λίστα Πινάκων

Πίνακας 1: Πληροφορίες των φωτοβολταϊκών εγκαταστάσεων που χρησιμοποιήθηκαν στις πειραματικές διαδικασίες της παρούσας εργασίας Σφάλμα! Δεν έχει οριστεί σελιδοδείκτης.	
Πίνακας 2: Ποσοστά Διαχωρισμού Συνόλου Δεδομένων για κάθε Φωτοβολταϊκό Σύστημα..... Σφάλμα! Δεν έχει οριστεί σελιδοδείκτης.	
Πίνακας 3: Συνολική Παρουσίαση Αποτελεσμάτων των Προσομοιώσεων με τις Μετρικές RMSE, MBE, nRMSE και R ² για όλες τις Στρατηγικές και όλα τα Φωτοβολταϊκά.....	84
Πίνακας 4: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV ₁	86
Πίνακας 5: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV ₂	87
Πίνακας 6: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV ₃	89
Πίνακας 7: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV ₄	90
Πίνακας 8: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV ₅	92
Πίνακας 9: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV ₆	93
Πίνακας 10: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV ₇	95

1 Εισαγωγή

Τα τελευταία χρόνια το παγκόσμιο ενεργειακό τοπίο έχει αλλάξει ριζικά και στρέφεται προς τις ανανεώσιμες πηγές ενέργειας προκειμένου να καλυφθούν οι ενεργειακές ανάγκες του ανθρώπινου πληθυσμού. Η άντληση ενέργειας από το φως του ηλίου, για παράδειγμα, είναι εφικτό να μας δώσει ποσότητες ενέργειας, μεγαλύτερες σε παραγωγή από αυτές που καταναλώνονται. Ο ρυθμός με τον οποίο η ηλιακή ενέργεια αναχαιτίζεται από τη Γη είναι περίπου 10.000 φορές μεγαλύτερος από τον ρυθμό με τον οποίο η ανθρωπότητα καταναλώνει ενέργεια [1].

1.1 Φωτοβολταϊκά Συστήματα


1.1.1 Ηλιακή Ενέργεια και Φωτοβολταϊκά Συστήματα

Η ηλιακή ενέργεια βρίσκεται σε αφθονία στον πλανήτη μας και μπορεί να συλλεχθεί ακόμα και με δυσμενείς καιρικές συνθήκες και γι' αυτό η χρήση φωτοβολταϊκών για τη συλλογή της είναι μία από τις πιο υποσχόμενες λύσεις ανανεώσιμων πηγών ενέργειας. Επιπλέον το κόστος κατασκευής και εγκατάστασης των ηλεκτρικών συλλεκτών έχει μειωθεί κατακόρυφα τα τελευταία χρόνια και έτσι προκαλεί οικονομική ελκυστικότητα, καθώς αποτελεί μια αμυδρά δαπανηρή μορφή άντλησης ηλεκτρικής ενέργειας. Αυτές είναι και κάποιες από τις αιτίες για τις οποίες σύμφωνα με την International Energy Agency (IEA) η ηλιακή φωτοβολταϊκή ισχύς αναμένεται να ξεπεράσει το φυσικό αέριο έως το 2026 και τον άνθρακα έως το 2027 [2]. Συγκεκριμένα, η παραγωγή φωτοβολταϊκών αυξήθηκε κατά 270 TWh (αύξηση 26%) το 2022, φτάνοντας σχεδόν τις 1 300 TWh. Παρουσίασε τη μεγαλύτερη απόλυτη αύξηση της παραγωγής από όλες τις τεχνολογίες ανανεώσιμων πηγών ενέργειας το 2022, ξεπερνώντας για πρώτη φορά στην ιστορία την αιολική ενέργεια όπως φαίνεται και στην εικόνα ένα (1).

1.1.2 Προκλήσεις στην Ενσωμάτωση Φωτοβολταϊκών Συστημάτων

Ωστόσο, από την θεωρία στην πράξη υπάρχει χάσμα. Η ενσωμάτωση φωτοβολταϊκών συστημάτων αποτελεί πρόκληση για τους περισσότερους, καθώς η παραγωγή εξαρτάται τόσο από τις καιρικές συνθήκες όσο και από τον τόπο εγκατάστασης, και η μεταβλητότητα αυτών ενέχει κινδύνους για ένα τέτοιο σύστημα. Ως εκ τούτου, είναι δέουσας σημασίας η ακριβής πρόβλεψη της παραγωγής ενέργειας, αφού μπορεί να φανεί βοηθητική στον σχεδιασμό και τη διαχείριση του δικτύου εξασφαλίζοντας αξιοπιστία στη συνεχόμενη παροχή

ενέργειας. Η ακριβής πρόβλεψη της παραγωγής χρησιμεύει, λοιπόν, ως άξονας σταθερότητας για το δίκτυο και αποτελεί το εργαλείο για την βιώσιμη ενεργειακή ολοκλήρωση [3].



Εικόνα 1: Fossil fuel capacity from IEA (2022), World Energy Outlook 2022 [2]

1.2 Πρόβλεψη Παραγωγής Ισχύος

1.2.1 Μέθοδοι Πρόβλεψης Παραγωγής Ενέργειας

Στα μέσα του 20ού αιώνα, οι πρώτες μέθοδοι πρόβλεψης βασίζονταν σε μεγάλο βαθμό σε αναλύσεις χρονοσειρών και μοντέλα γραμμικής παλινδρόμησης. Ωστόσο, όπως περιγράφεται στο έργο των S. Makridakis et al. (1998) στην δημοσίευσή τους "Forecasting: Methods and Applications" [4], ο τομέας υπέστη μια αλλαγή προς την κατεύθυνση της υιοθέτησης πιο προηγμένων τεχνικών, όπως τα τεχνητά νευρωνικά δίκτυα και οι αλγόριθμοι μηχανικής μάθησης. Αυτό επιβεβαιώνεται και από πρωτοποριακές μελέτες, όπως αυτές που διεξήχθησαν από τους Dávid Markovics, Martin János Mayer [5], Kathrine Lau Jørgensen; Hamid

Reza Shaker [6] και Martin János Mayer [7] στις αντίστοιχες δημοσιεύσεις τους, οι οποίες υπογραμμίζουν τη σημασία της ενσωμάτωσης μετεωρολογικών δεδομένων και ιδιαίτερα των νευρωνικών δικτύων με χρήση αλγορίθμων μηχανικής μάθησης για την πρόβλεψη της παραγωγής ενέργειας από ανανεώσιμες πηγές.

1.2.2 Νευρωνικά Δίκτυα στην Πρόβλεψη Ισχύος

Η δύναμη των νευρωνικών δικτύων έγκειται στην ικανότητά τους να επεξεργάζονται διάφορους τύπους δεδομένων, από ιστορικά αρχεία έως δυναμικούς περιβαλλοντικούς παράγοντες, όπως οι καιρικές συνθήκες. Αυτή η προσαρμοστικότητα είναι ιδιαίτερα επωφελής για την αποτύπωση της πολύπλευρης φύσης των συστημάτων ηλεκτρικής ενέργειας, που χαρακτηρίζονται από περίπλοκες εξαρτήσεις και απρόβλεπτες διακυμάνσεις. Επιπλέον, με την χρήση ιστορικών δεδομένων είναι εφικτή η επαναληπτική διαδικασία εκμάθησης προκειμένου να γίνουν προσαρμογές στις παραμέτρους του δικτύου και να επιτευχθεί η ελαχιστοποίηση των αποκλίσεων μεταξύ των προβλεπόμενων και των πραγματικών τιμών ισχύος. Τέτοια νευρωνικά δίκτυα είναι τα Recurrent Neural Networks (RNN) [8], Convolutional Neural Networks (CNN) και Long Short-Term Memory networks (LSTM) [9], [10], τα οποία είναι και τα επικρατέστερα για την πρόβλεψη ισχύος με χειρισμό δεδομένων χρονοσειρών (Time-Series Forecasting).

1.2.3 Ζητήματα Προστασίας Προσωπικών Δεδομένων

Παρ' όλα αυτά, ο χειρισμός των δεδομένων δεν είναι πάντοτε εφικτός. Δεδομένα τέτοιου τύπου, θεωρούνται πολλές φορές μη προσβάσιμα λόγω του ότι μπορεί να αποκαλύψουν ευαίσθητες και προσωπικές πληροφορίες. Ιδιαίτερα τα τελευταία χρόνια, που έχουν θεσπιστεί πρωτόκολλα, νόμοι και κανονισμοί περί της ιδιωτικότητας των προσωπικών δεδομένων όπως οι General Data Protection Regulation (GDPR) [11] και Health Insurance Portability and Accountability Act (HIPAA) [12], η πρόσβαση σε ιστορικά δεδομένα ενέργειας και η επεξεργασία αυτών είναι απαγορευτική. Επομένως καθίσταται δύσκολη έως και αδύνατη σε ορισμένες περιπτώσεις η δημιουργία μοντέλων πρόβλεψης που βασίζονται στην συγκομιδή μεγάλου όγκου προσωπικών δεδομένων.

1.3 Federated Learning (FL)

1.3.1 Εισαγωγή στο Federated Learning

Την λύση στην παραπάνω αντιξοότητα είναι σε θέση να προσφέρει η τεχνική του Federated Learning (FL). Πρόκειται για ένα κλάδο της μηχανικής μάθησης όπου πολλές αποκεντρωμένες οντότητες (entities), ή πελάτες (clients) όπως συνηθίζονται

να λέγονται, συνεργάζονται ώστε να εκπαιδεύσουν ένα από κοινού μοντέλο μηχανικής μάθησης, διασφαλίζοντας το απόρρητο των δεδομένων που η κάθε οντότητα διαθέτει [13]. Η εκπαίδευση γίνεται από κάθε οντότητα τοπικά και τα μοντέλα που προκύπτουν συνθέτουν ένα νέο καθολικό αθροιστικό μοντέλο, χωρίς να ανταλλάσσονται δεδομένα μεταξύ των clients. Με αυτό τον τρόπο διατηρείται η ιδιωτικότητα των δεδομένων καθώς καμία οντότητα δεν διαμοιράζεται δεδομένα ούτε με άλλες οντότητες αλλά ούτε και με τον κεντρικό server.

Λίγοι είναι οι αποκεντρωμένοι αλγόριθμοι πρόβλεψης όπως το FL και για αυτό είναι δύσκολο να γίνει αντιληπτή η σημασία του και είναι ελάχιστες οι μελέτες και οι φορές που έχει χρησιμοποιηθεί αυτή η τεχνική για πρόβλεψη. Η πιο συνηθισμένη στρατηγική, ωστόσο, η οποία χρησιμοποιείται τις περισσότερες φορές όταν εφαρμόζεται το FL είναι η Federated Averaging (FedAvg) [14]. Όπως αναφέρθηκε και προηγουμένως, τα τοπικά μοντέλα υπολογίζουν ενημερώσεις παραμέτρων χρησιμοποιώντας τοπικά δεδομένα, και αυτές οι ενημερώσεις στη συνέχεια υπολογίζονται κατά μέσο όρο για να ληφθεί μια συνολική ενημέρωση, εξασφαλίζοντας τη σύγκλιση προς ένα κοινό μοντέλο, διατηρώντας παράλληλα το απόρρητο. Η διαδικασία αυτή επαναλαμβάνεται για αρκετούς γύρους και κάθε γύρος περιλαμβάνει τόσο την εκπαιδευτική όσο και την αθροιστική διεργασία (training and aggregation). Άλλες στρατηγικές ευρέως γνωστές που χρησιμοποιούνται είναι επίσης:

- Το Differential Privacy [15], το οποίο προσθέτει, με ελεγχόμενο τρόπο, θόρυβο κατά την διάρκεια των υπολογισμών, διασφαλίζοντας ότι δεν θα γίνουν αντιληπτά μεμονωμένα δεδομένα, ώστε να προστατευτεί το απόρρητο.
- Το Secure Aggregation [16], κατά το οποίο κρυπτογραφούνται οι ενημερώσεις των μοντέλων κατά την διάρκεια όλων των μεταδόσεων ώστε να παραμένουν ιδιωτικά όλα τα δεδομένα και να γίνεται σωστή χρήση του FL.
- Το Client Selection Strategy [17], το οποίο αποφασίζει για τα ποιες συσκευές θα συμμετέχουν σε κάθε γύρο εκπαίδευσης, προκειμένου να υπάρχει ισορροπία στη χρήση υπολογιστικών πόρων και στην ποικιλομορφία των ιστορικών δεδομένων.
- Το Adaptive Learning Rate Scheduling [18], το οποίο προσαρμόζει τον ρυθμό μάθησης κάθε συσκευής ξεχωριστά με κριτήριο την απόδοση και την συνεισφορά τους, ενισχύοντας την ταχύτητα σύγκλισης του αλγορίθμου του FL και την σταθερότητα αυτού.

1.3.2 Προκλήσεις στο Federated Learning

Η ανάγκη ύπαρξης των παραπάνω στρατηγικών έγκειται στις διάφορες προκλήσεις που μπορεί να πρέπει να αντιμετωπιστούν κατά την διάρκεια εκτέλεσης αλγορίθμων FL. Τέτοιες προκλήσεις είναι η διαφορά στους υπολογιστικούς πόρους που μπορεί να έχουν οι οντότητες μεταξύ τους [19], η ποιότητα του δικτύου επικοινωνίας μεταξύ των οντοτήτων και του server [20], η διαθεσιμότητα των οντοτήτων την ώρα που καλούνται [21], καθώς και η στατιστική ετερογένεια που υπάρχει μεταξύ των δεδομένων από διαφορετικές οντότητες [22].

Πιο αναλυτικά, οι υπολογιστικές δυνατότητες και τα υλικά που συνθέτουν μια συσκευή, ενδέχεται να διαφέρουν από οντότητα σε οντότητα με αποτέλεσμα να υπάρχει σημαντική απόκλιση στους χρόνους απόκρισης και κατά συνέπεια στον συνολικό συντονισμό του όλου συστήματος. Επιπλέον η ποιότητα των δικτυακών συνδέσεων μεταξύ του κεντρικού διακομιστή και των συμμετεχουσών οντοτήτων επηρεάζει την επικοινωνία και μπορεί να οδηγήσει στην παρεμπόδιση της έγκαιρης συγκέντρωσης των ενημερωμένων μοντέλων. Το ίδιο συμβαίνει και στην περίπτωση που κάποιες οντότητες δεν είναι σε κατάσταση διαθεσιμότητας και δηλαδή δεν είναι έτοιμες και σε θέση να επικοινωνήσουν με τον κεντρικό server λόγω τεχνικών προβλημάτων για παράδειγμα. Τέλος, ποικιλία οντοτήτων συνεπάγεται ποικιλία και ετερογένεια στα δεδομένα αυτών. Τα μη ταυτόσημα δεδομένα οδηγούν στην δημιουργία ενός κοινού μοντέλου το οποίο παραλείπει τις ιδιαιτερότητες που μπορεί να έχουν ορισμένες οντότητες και συνεπώς η χρήση του κεντρικού μοντέλου σε αυτές, θα έχει χειρότερες επιδόσεις από μοντέλα που εκπαιδεύονται μόνο με τοπικά δεδομένα.

1.4 Έρευνες και Περιορισμοί στην Πρόβλεψη Φωτοβολταϊκής Ισχύος

Τα βαθιά νευρωνικά δίκτυα (Deep Neural Networks) έχουν εξελιχθεί σε μία από τις πιο συχνά χρησιμοποιούμενες προσεγγίσεις για την πρόβλεψη ισχύος φωτοβολταϊκών συστημάτων [23]. Χάρη στην ικανότητά τους να αποτυπώνουν πολύπλοκες, μη γραμμικές σχέσεις μεταξύ των χαρακτηριστικών εισόδου και των στόχων εξόδου αποτελούν ένα ισχυρό εργαλείο και αποτελεσματική λύση για προβλήματα που αφορούν την πρόβλεψη ενέργειας. Ωστόσο, η πλειονότητα των υπάρχουσων ερευνών αξιοποιεί συγκεντρωτικούς αλγορίθμους (centralized prediction algorithms) DNN για την πρόβλεψη της φωτοβολταϊκής ισχύος [24]. Τα συγκεντρωτικά μοντέλα βασίζονται στην επαρκή συγκέντρωση δεδομένων από πολλαπλές φωτοβολταϊκές πηγές στον κεντρικό διακομιστή [25] και γι' αυτό ενδέχεται να αντιμετωπίζουν προβλήματα με την διαφύλαξη της ιδιωτικότητας των δεδομένων. Οι ανησυχίες για την προστασία της ιδιωτικής ζωής συχνά εμποδίζουν

την προθυμία των κατόχων δεδομένων, όπως οι μεμονωμένοι φορείς εκμετάλλευσης φωτοβολταϊκών συστημάτων ή οι εταιρείες κοινής ωφέλειας, να μοιραστούν τα ακατέργαστα δεδομένα τους, οδηγώντας σε περιορισμούς στη διαθεσιμότητα και την πληρότητα των δεδομένων. Ως εκ τούτου δεν είναι πάντοτε εφικτή η εκπαίδευση ενός αποδοτικού μοντέλου. Επιπλέον, οι συγκεντρωτικοί αλγόριθμοι, λόγω της ανεπάρκειας των δεδομένων τείνουν να υπερπροσαρμόζονται και δεν μπορούν να διαχειριστούν την ετερογένεια και την ποικιλομορφία που υπάρχει στα συλλεχθέντα δεδομένα φωτοβολταϊκής ισχύος [26]. Τα δεδομένα προέρχονται από διάφορες πηγές με διαφορετικές κλιματολογικές συνθήκες, διαμορφώσεις συστημάτων και λειτουργικές συμπεριφορές, δημιουργώντας ένα πολύπλοκο σύνολο δεδομένων, το οποίο οι συγκεντρωτικές προσεγγίσεις πρόβλεψης, αδυνατούν να αξιοποιήσουν ικανοποιητικά.

Για την αντιμετώπιση των προαναφερθέντων προβληματισμών προτείνεται η εφαρμογή της τεχνικής του Federated Learning. Το FL αντιμετωπίζει αυτές τις προκλήσεις επιτρέποντας την τοπική εκπαίδευση των μοντέλων στις εγκαταστάσεις κάθε πηγής δεδομένων χωρίς τη μεταφορά ακατέργαστων δεδομένων, διατηρώντας έτσι την ιδιωτικότητα. Ενισχύει επίσης την διαχείριση ποικιλόμορφων και ετερογενών δεδομένων καθώς η επικοινωνία του κεντρικού διακομιστή με τις συνεργαζόμενες εγκαταστάσεις, δεν πραγματοποιείται με την ανταλλαγή ωμών δεδομένων αλλά με παραμέτρους των ενημερώσεων των τοπικών μοντέλων [27]. Έχει αποδειχθεί ότι το FL όχι μόνο επιλύει τα ζητούμενα προστασίας των δεδομένων αλλά αξιοποιώντας την ποικιλομορφία των δεδομένων βελτιώνει την προβλεπτική απόδοση των DNN μεθόδων [28].

Επομένως το Federated Learning προσφέρει μια λειτουργική λύση στους περιορισμούς που θέτουν οι συγκεντρωτικοί αλγόριθμοι εκπαίδευσης εξαλείφοντας τις ανησυχίες ιδιωτικότητας των δεδομένων και τις προκλήσεις που προκύπτουν από την ποικιλία και την ετερογένεια των δεδομένων. Το παρόν έργο, όχι μόνο αξιοποιεί την τεχνική του Federated Learning, αλλά διαφοροποιείται από την ερευνητική κοινότητα με την εκμετάλλευση έξι (6) στρατηγικών συνάθροισης. Στο έως τώρα ερευνητικό προσκήνιο, στις περισσότερες περιπτώσεις η συνάθροιση των ενημερώσεων γίνεται με τη χρήση της στρατηγικής Federated Averaging (FedAvg) [29]. Για την πρόβλεψη της φωτοβολταϊκής ενέργειας και ισχύος, η παρούσα εργασία χρησιμοποιεί ένα νευρωνικό δίκτυο LSTM και πολλαπλές στρατηγικές σύγκλισης, μεταξύ αυτών και η FedAvg, επιλύοντας τα καίρια προβλήματα που αναφέρθηκαν και διερευνά τις επιπτώσεις εφαρμογής διαφορετικών αλγορίθμων Federated Learning στην ακρίβεια των προβλέψεων.

1.5 Συνεισφορές της Παρούσας Εργασίας

Οι κύριες συνεισφορές της παρούσας εργασίας συνοψίζονται ως εξής:

Η παρούσα εργασία προτείνει και υλοποιεί ένα νευρωνικό δίκτυο LSTM που χρησιμοποιεί την τεχνική του Federated Learning για την πρόβλεψη της φωτοβολταϊκής ενέργειας και ισχύος. Η προσέγγιση αυτή διασφαλίζει την προστασία της ιδιωτικότητας των δεδομένων και αντιμετωπίζει τις προκλήσεις της ποικιλίας και ετερογένειας των δεδομένων που συλλέγονται από διαφορετικές οντότητες, προσφέροντας ένα πιο ακριβές και εξατομικευμένο μοντέλο πρόβλεψης σε σύγκριση με τα παραδοσιακά συγκεντρωτικά μοντέλα. Η καινοτομία της αφορά την διερεύνηση των επιπτώσεων της επιλογής αλγορίθμων και στρατηγικών σύγκλισης στη βελτίωση της απόδοσης και ανθεκτικότητας των προβλέψεων, συμβάλλοντας σημαντικά στην πρόοδο της τεχνολογίας πρόβλεψης φωτοβολταϊκής ισχύος.

1.6 Δομή του Υπόλοιπου Εγγράφου

Στην ενότητα δύο (2) αναλύονται οι χρονικοί ορίζοντες πρόβλεψης, εστιάζοντας ιδιαίτερα στη βραχυπρόθεσμη πρόβλεψη που είναι κρίσιμη για τον ενεργειακό προγραμματισμό. Ακολουθεί μια αναλυτική περιγραφή των μεθόδων πρόβλεψης και παρουσιάζεται το Federated Learning καθώς και το μοντέλο LSTM. Στην ενότητα τρία (3) παρουσιάζονται συναφείς εργασίες, τόσο του τομέα της βραχυπρόθεσμης πρόβλεψης, όσο και του τομέα του Federated Learning, ενώ στην ενότητα τέσσερα (4) παρατίθενται τα εργαλεία που χρησιμοποιήθηκαν και περιγράφεται αναλυτικά το σύνολο δεδομένων. Ακολουθεί στην ενότητα πέντε (5) η μεθοδολογία που εκτελέστηκε, η οποία περιλαμβάνει τον μαθηματικό χειρισμό της πρόβλεψης φωτοβολταϊκής ισχύος και τα χαρακτηριστικά του Federated Learning Framework μαζί με τον αλγόριθμο και τον ψευδοκώδικα. Στο τέλος της ενότητας αναλύονται και οι στρατηγικές Federated Learning. Τέλος, στην ενότητα έξι (6) γίνεται η ανάλυση των μετρικών αξιολόγησης και σαφώς η παρουσίαση και ο σχολιασμός των αποτελεσμάτων από την διεξαγωγή των πειραμάτων. Η εργασία ολοκληρώνεται με τις ενότητες επτά (7) και οκτώ (8), όπου συνάγονται τα συμπεράσματα και οι προτάσεις μελλοντικής εξέλιξης και παρατίθεται η βιβλιογραφία των εργασιών που αξιοποιήθηκαν καθ' όλη την διάρκεια διεξαγωγής της παρούσας έρευνας.

2 Θεωρητικό Υπόβαθρο

2.1 Χρονικοί Ορίζοντες PV Power Forecasting

Στο πεδίο της ενσωμάτωσης των ανανεώσιμων πηγών ενέργειας, ιδίως στο πλαίσιο της ηλιακής ενέργειας, η αποτελεσματική διαχείριση της παραγωγής απαιτεί πρόβλεψη της φωτοβολταϊκής (ΦΒ) ισχύος, η οποία επηρεάζεται από διάφορους ατμοσφαιρικούς και περιβαλλοντικούς παράγοντες. Όπως περιγράφεται και στο έργο των Ismail Kaaya and Julián Ascencio-Vásquez [30], η πρόβλεψη της φωτοβολταϊκής ισχύος περιλαμβάνει διακριτούς χρονικούς ορίζοντες, που κυμαίνονται από πολύ βραχυπρόθεσμες (very short-term) έως μακροπρόθεσμες προβλέψεις (long-term), καθεμία από τις οποίες εξυπηρετεί συγκεκριμένους επιχειρησιακούς και στρατηγικούς σκοπούς.

2.1.1 Βραχυπρόθεσμη Πρόβλεψη (Short-Term Forecasting)

Κύριο εργαλείο στη διασφάλιση της σταθερότητας του δικτύου και του αποτελεσματικού εμπορίου ενέργειας αποτελεί η βραχυπρόθεσμη πρόβλεψη. Η βραχυπρόθεσμη πρόβλεψη εκτείνεται από λεπτά έως ώρες και επιτρέπει την εύκολη και γρήγορη προσαρμογή των συστημάτων στις παροδικές διακυμάνσεις της ηλιακής παραγωγής που προκαλούνται από ατμοσφαιρικά φαινόμενα όπως τα διερχόμενα σύννεφα ή οι ταχείες αλλαγές στις καιρικές συνθήκες. Βασίζεται στην περισυλλογή δεδομένων σε πραγματικό χρόνο από διάφορες πηγές που περιλαμβάνουν τόσο μετεωρολογικούς δορυφόρους όσο και επίγειους αισθητήρες και χρησιμοποιώντας εξελιγμένα αριθμητικά μοντέλα πρόβλεψης καιρού διευκολύνει τον προγραμματισμό και τη διαχείριση των αποθηκευμένων ενεργειακών πόρων καθώς και την χρήση αυτών στο συνολικό ενεργειακό μείγμα [31].

2.1.2 Μεσοπρόθεσμη Πρόβλεψη (Medium-Term Forecasting)

Επιπλέον, οι μεσοπρόθεσμες προβλέψεις, που εκτείνονται από ημέρες έως εβδομάδες, διαδραματίζουν καθοριστικό ρόλο στον μεσοπρόθεσμο σχεδιασμό και την κατανομή των πόρων στον ενεργειακό τομέα. Χρησιμοποιώντας στατιστικές μεθοδολογίες και ιστορικά κλιματολογικά δεδομένα, οι μεσοπρόθεσμες προβλέψεις προσφέρουν πολύτιμες πληροφορίες για την αναμενόμενη ηλιακή ακτινοβολία και την παραγωγή ισχύος από φωτοβολταϊκά, ενημερώνοντας για αποφάσεις που αφορούν τον προγραμματισμό συντήρησης, τη διαχείριση του εφοδιασμού καυσίμων και τη βελτιστοποίηση των λειτουργιών του δικτύου. Οι προβλέψεις αυτές, αν και λιγότερο λεπτομερείς από τις αντίστοιχες

βραχυπρόθεσμες, συμβάλλουν σημαντικά στη στρατηγική τοποθέτηση της ηλιακής ενέργειας στο ευρύτερο ενεργειακό τοπίο.

2.1.3 Μακροπρόθεσμη Πρόβλεψη (Long-Term Forecasting)

Δεν μπορεί να παραβλεφθεί, ωστόσο, η σημασία των μακροπρόθεσμων προβλέψεων, ιδίως όσον αφορά τον στρατηγικό σχεδιασμό, τις επενδυτικές αποφάσεις και τη διαμόρφωση πολιτικής. Με χρονικό ορίζοντα που υπερβαίνει τις εβδομάδες και περιλαμβάνει χρόνια, η μακροπρόθεσμη πρόβλεψη χρησιμοποιεί κλιματικά μοντέλα και αναλύσεις τάσεων για την πρόβλεψη της μελλοντικής ηλιακής ακτινοβολίας και της παραγωγής φωτοβολταϊκής ισχύος. Μια τέτοια πρόβλεψη είναι άκρως χρήσιμη για την καθοδήγηση αποφάσεων, σε μια περίοδο τεχνολογικών εξελίξεων και αλλαγών κανονιστικών πλαισίων και οικονομικών τάσεων, προκειμένου να υπάρχει βιώσιμη και αειφόρος ανάπτυξη ηλιακής ενέργειας.

Όλοι οι παραπάνω χρονικοί ορίζοντες που οριοθετούν την πρόβλεψη της φωτοβολταϊκής ισχύος βρίσκουν απήχηση σε διάφορους και διαφορετικούς τομείς όσον αφορά το ευρύτερο ενεργειακό τοπίο. Οι ερευνητές, ωστόσο, επικεντρώνονται στην βραχυπρόθεσμη πρόβλεψη προκειμένου να διευκολυνθεί ο ενεργειακός προγραμματισμός των φωτοβολταϊκών, ώστε να υπάρχει προνοητικότητα και ακρίβεια. Για τον ίδιο λόγο και η παρούσα εργασία θα επικεντρωθεί στη βραχυπρόθεσμη πρόβλεψη.

2.2 Μέθοδοι PV Power Forecasting και ANN

Εκτός, όμως, του διαχωρισμού με βάση τους χρονικούς ορίζοντες της πρόβλεψης, μπορούμε να διακρίνουμε κατηγορίες πρόβλεψης της ισχύος των φωτοβολταϊκών με κριτήριο τη μέθοδο/προσέγγιση που χρησιμοποιείται. Πιο αναλυτικά, οι προσεγγίσεις αυτές μπορούν να κατηγοριοποιηθούν σε γενικές γραμμές σε φυσικές μεθόδους (physical methods), στατιστικές μεθόδους (statistical methods) και μεθόδους τεχνητών νευρωνικών δικτύων (Artificial Neural Networks (ANN) methods).

2.2.1 Φυσικές Μέθοδοι (Physical Methods)

Οι φυσικές ή ντετερμινιστικές μέθοδοι πρόβλεψης [32] βασίζονται στις θεμελιώδεις αρχές της φυσικής για τη μοντελοποίηση της παραγωγής φωτοβολταϊκής ισχύος. Αυτές οι μέθοδοι λαμβάνουν υπόψη τις γεωγραφικές και κλιματικές συνθήκες του τόπου εγκατάστασης των ΦΒ, συμπεριλαμβανομένης της ηλιακής ακτινοβολίας, της θερμοκρασίας και της γωνίας των ηλιακών συλλεκτών.

Τα φυσικά μοντέλα προσομοιώνουν τα ηλεκτρικά χαρακτηριστικά του φωτοβολταϊκού συστήματος για να προβλέψουν την παραγωγή ισχύος. Απαιτούν λεπτομερή δεδομένα σχετικά με τα εξαρτήματα του συστήματος και το περιβάλλον. Για παράδειγμα, χρησιμοποιούν μοντέλα μεταφοράς ακτινοβολίας για την εκτίμηση της ηλιακής ακτινοβολίας στην επιφάνεια της γης.

- Πλεονεκτήματα: Υψηλή ακρίβεια βραχυπρόθεσμα και υπό συνθήκες καθαρού ουρανού- χρήσιμα για την κατανόηση των φυσικών αλληλεπιδράσεων εντός του συστήματος.
- Περιορισμοί: Λιγότερο αποτελεσματικά υπό αβέβαιες καιρικές συνθήκες.

2.2.2 Στατιστικές Μέθοδοι (Statistical Methods)

Οι στατιστικές μέθοδοι πρόβλεψης [33] χρησιμοποιούν ιστορικά δεδομένα για να προβλέψουν τη μελλοντική ισχύ των φωτοβολταϊκών συστημάτων. Αυτές οι μέθοδοι εντοπίζουν πρότυπα και σχέσεις μεταξύ της παραγωγής ισχύος και διαφόρων παραγόντων επιρροής, όπως η ηλιακή ακτινοβολία, η θερμοκρασία και η ώρα της ημέρας. Οι συνήθεις στατιστικές μέθοδοι περιλαμβάνουν μοντέλα χρονοσειρών (π.χ. ARIMA), μοντέλα παλινδρόμησης και τεχνικές μηχανικής μάθησης, όπως μηχανές διανυσμάτων υποστήριξης (SVM).

- Ανάλυση χρονοσειρών: Μοντελοποιεί τα διαδοχικά δεδομένα της φωτοβολταϊκής παραγωγής, λαμβάνοντας υπόψη την εποχικότητα και τις τάσεις.
- Μοντέλα παλινδρόμησης: Καθιέρωση μαθηματικών σχέσεων μεταξύ της φωτοβολταϊκής ισχύος εξόδου και των παραγόντων επιρροής.
- Τεχνικές μηχανικής μάθησης: SVM και άλλοι αλγόριθμοι μαθαίνουν σύνθετα μοτίβα από ιστορικά δεδομένα για να προβλέψουν τη μελλοντική παραγωγή.
- Πλεονεκτήματα: Μπορούν να χειριστούν μεγάλα σύνολα δεδομένων.
- Περιορισμοί: Απαιτεί προεπεξεργασία των δεδομένων.

2.2.3 Μέθοδοι Τεχνητών Νευρωνικών Δικτύων (Artificial Neural Networks (ANN) methods)

Οι μέθοδοι ANN [34], ένα υποσύνολο της μηχανικής μάθησης, είναι εμπνευσμένες από τη νευρωνική δομή του ανθρώπινου εγκεφάλου. Αποτελούνται από διασυνδεδεμένους κόμβους ή νευρώνες που επεξεργάζονται πληροφορίες

χρησιμοποιώντας ένα σύνολο βαρών που προσαρμόζονται καθώς το δίκτυο μαθαίνει. Οι μέθοδοι ANN είναι ιδιαίτερα αποτελεσματικές στη μοντελοποίηση πολύπλοκων, μη γραμμικών σχέσεων. Στο πλαίσιο της πρόβλεψης της ισχύος των φωτοβολταϊκών, τα ANN λαμβάνουν εισροές όπως η ηλιακή ακτινοβολία, η θερμοκρασία και ιστορικά δεδομένα παραγωγής ισχύος για να προβλέψουν τη μελλοντική παραγωγή ισχύος.

- Νευρωνικά δίκτυα τροφοδότησης (Feedforward Neural Networks): Η απλούστερη μορφή των ANN, όπου τα δεδομένα κινούνται προς μία κατεύθυνση από τα στρώματα εισόδου μέσω των κρυφών στρωμάτων (εάν υπάρχουν) προς τα στρώματα εξόδου. Αυτά τα δίκτυα είναι ικανά να χειρίζονται εργασίες όπως η παλινδρόμηση και η ταξινόμηση.
- Multilayer Perceptrons (MLPs): Τα Multilayer Perceptrons είναι ένας συγκεκριμένος FNN με πολλαπλά στρώματα νευρώνων, συμπεριλαμβανομένων των στρωμάτων εισόδου, των κρυφών στρωμάτων και των στρωμάτων εξόδου. Τα MLP είναι ικανά να μαθαίνουν πολύπλοκα πρότυπα και χρησιμοποιούνται εκτενώς σε διάφορους τομείς, όπως η αναγνώριση εικόνων, η επεξεργασία φυσικής γλώσσας και η πρόβλεψη χρονοσειρών.
- Επαναλαμβανόμενα νευρωνικά δίκτυα (Recurrent Neural Networks (RNN)): Κατάλληλα για διαδοχικά δεδομένα, τα RNN έχουν βρόχους ανατροφοδότησης που επιτρέπουν τη διατήρηση των πληροφοριών, επιτρέποντάς τους να καταγράφουν τις χρονικές εξαρτήσεις και καθιστώντας τα ιδανικά για μοντελοποίηση γλώσσας, αναγνώριση ομιλίας και ιδιαίτερα πρόβλεψη χρονοσειρών.
- Δίκτυα μακράς βραχυπρόθεσμης μνήμης (Long Short-Term Memory Networks (LSTM)): Τα Δίκτυα Μακράς Βραχυπρόθεσμης Μνήμης είναι μια εξειδικευμένη παραλλαγή των RNNs που έχει σχεδιαστεί για να μετριάσει το πρόβλημα της εξαφανιζόμενης κλίσης (vanishing gradient) που αντιμετωπίζεται κατά την εκπαίδευση των παραδοσιακών RNNs σε μεγάλες ακολουθίες. Τα LSTM ενσωματώνουν memory cells (κύτταρα μνήμης) και gating mechanisms για τη ρύθμιση της ροής των πληροφοριών, διευκολύνοντας τη μάθηση μακροχρόνιων εξαρτήσεων. Είναι αποτελεσματικά σε εργασίες που απαιτούν τη διατήρηση πληροφοριών σχετικά με το πλαίσιο δραστηριοποίησης, σε εκτεταμένες ακολουθίες, όπως η μηχανική μετάφραση, η αναγνώριση ομιλίας και η ανάλυση συναισθήματος. Ιδιαίτερα αποτελεσματικά είναι και στην πρόβλεψη φωτοβολταϊκής ισχύος, καθώς τα LSTM προσφέρουν σημαντικά

πλεονεκτήματα λόγω της ικανότητάς τους να δημιουργούν πολύπλοκες χρονικές εξαρτήσεις στα πρότυπα παραγωγής ηλιακής ενέργειας.

- Συνελικτικά νευρωνικά δίκτυα (Convolutional Neural Networks (CNN)): Τα συνελικτικά νευρωνικά δίκτυα έχουν σχεδιαστεί ειδικά για την επεξεργασία δομών δεδομένων που μοιάζουν με πλέγμα, όπως οι εικόνες. Χρησιμοποιούν στρώματα συνελικτικού τύπου για την ανίχνευση χωρικών μοτίβων με ολίσθηση φίλτρων (πυρήνες) πάνω στα δεδομένα εισόδου, ακολουθούμενα από στρώματα συγκέντρωσης για τη μείωση της διαστατικότητας. Αν και χρησιμοποιούνται κυρίως στην επεξεργασία εικόνας, τα CNN μπορούν επίσης να εφαρμοστούν στην πρόβλεψη χρονοσειρών, αντιμετωπίζοντας τα δεδομένα ως μονοδιάστατη εικόνα.
- Generative Adversarial Networks (GAN): Τα Generative Adversarial Networks αποτελούνται από δύο νευρωνικά δίκτυα -μια γεννήτρια και έναν διαχωριστή- που εκπαιδεύονται ταυτόχρονα σε ένα ανταγωνιστικό πλαίσιο. Η γεννήτρια μαθαίνει να παράγει δεδομένα που μοιάζουν με την κατανομή των δεδομένων εκπαίδευσης, ενώ ο διαχωριστής μαθαίνει να διακρίνει μεταξύ πραγματικών και ψεύτικων δεδομένων. Οι GAN έχουν αποκτήσει εξέχουσα θέση στα ANNs για την ικανότητά τους να παράγουν ρεαλιστικές εικόνες, βίντεο και ήχο, καθώς και για εφαρμογές όπως η αύξηση δεδομένων και η ανίχνευση ανωμαλιών.
 - Πλεονεκτήματα: Ικανότητα χειρισμού μη γραμμικών σχέσεων και αλληλεπιδράσεων μεταξύ των μεταβλητών- ευελιξία στην ενσωμάτωση διαφόρων τύπων δεδομένων.
 - Περιορισμοί: Η αρχιτεκτονική του μοντέλου και η ρύθμιση των υπερπαραμέτρων μπορεί να είναι πολύπλοκη και χρονοβόρα.

Η επιλογή της μεθόδου πρόβλεψης εξαρτάται από τις ειδικές απαιτήσεις του φωτοβολταϊκού συστήματος, συμπεριλαμβανομένου του ορίζοντα πρόβλεψης (βραχυπρόθεσμος ή μακροπρόθεσμος), της διαθεσιμότητας των δεδομένων, των υπολογιστικών πόρων και του επιπέδου ακρίβειας που απαιτείται. Συχνά, χρησιμοποιείται μια υβριδική προσέγγιση που συνδυάζει πολλαπλές μεθόδους για να αξιοποιηθούν τα πλεονεκτήματα της καθεμιάς και να βελτιωθεί η συνολική απόδοση της πρόβλεψης. Για παράδειγμα, ο συνδυασμός φυσικών μοντέλων με μεθόδους ANN μπορεί να βελτιώσει την ακρίβεια της πρόβλεψης ενσωματώνοντας τόσο τη φυσική κατανόηση του συστήματος όσο και τις δυνατότητες αναγνώρισης προτύπων της μηχανικής μάθησης [85] [86]. Στη παρούσα εργασία όμως χρησιμοποιείται η μέθοδος των τεχνητών νευρωνικών δικτύων (ANN) και

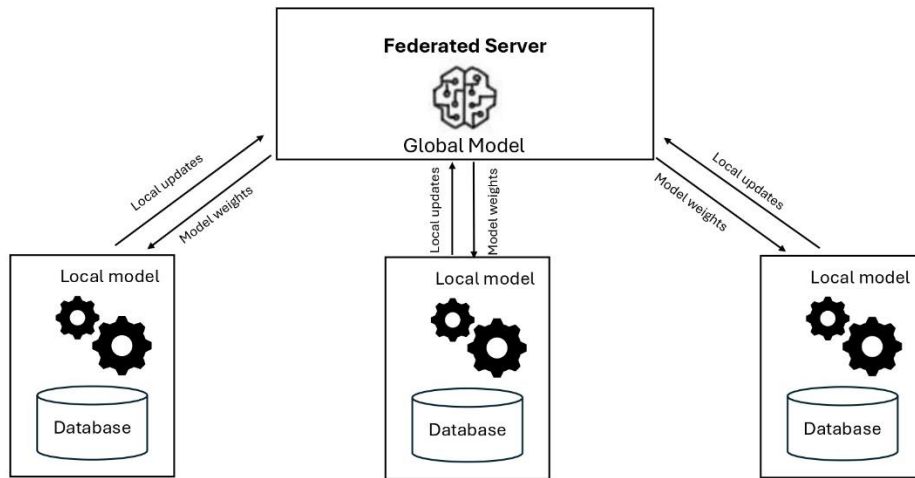
συγκεκριμένα ενός δικτύου μακράς βραχυπρόθεσμης μνήμης (LSTM) για την πρόβλεψη της φωτοβολταϊκής ενέργειας και ισχύος.

Προκειμένου να είναι αποτελεσματική η χρήση ενός LSTM δικτύου απαραίτητη προϋπόθεση είναι η ύπαρξη αρκετών δεδομένων εκπαίδευσης που από τις διασκορπισμένες συσκευές θα συγκεντρώνονται στον κεντρικό διακομιστή, ώστε να εκπαιδευτεί ένα συλλογικό μοντέλο. Κάτι τέτοιο ωστόσο θα δημιουργούσε πρόβλημα όσον αφορά την προστασία των δεδομένων και την ιδιωτικότητα αυτών, και επομένως ο διαμοιρασμός των δεδομένων μεταξύ των συσκευών και του διακομιστή θα ήταν δύσκολος έως και αδύνατος [83] [84].

2.3 Federated Learning

2.3.1 Εισαγωγή στο Federated Learning

Τα τελευταία χρόνια, το Federated Learning (FL) έχει αναδειχθεί ως μια πολλά υποσχόμενη λύση στις προκλήσεις που θέτουν οι ανησυχίες για την προστασία της ιδιωτικής ζωής των δεδομένων στο πεδίο της μηχανικής μάθησης και δηλαδή στο ζητούμενο που μας απασχολεί. Το FL αντιπροσωπεύει ένα παράδειγμα κατανεμημένης μάθησης που στοχεύει στη συνεργατική εκπαίδευση μοντέλων σε διαφορετικές συσκευές, ενώ παράλληλα τηρεί αυστηρά πρότυπα προστασίας της ιδιωτικής ζωής. Σε αντίθεση με τις παραδοσιακές συγκεντρωτικές προσεγγίσεις, το FL λειτουργεί με αποκεντρωμένες προϋποθέσεις, όπου κάθε συμμετέχουσα συσκευή εκπαιδεύει αυτόνομα ένα τοπικό μοντέλο χρησιμοποιώντας το δικό της σύνολο δεδομένων. Ειδικότερα, μόνο οι ενημερώσεις του μοντέλου, συνήθως με τη μορφή βαρών, διαβιβάζονται σε έναν κεντρικό διακομιστή, παρακάμπτοντας την ανάγκη ανταλλαγής ακατέργαστων δεδομένων. Μέσω της επαναληπτικής συνάθροισης (aggregation) αυτών των ενημερώσεων, συντίθεται ένα παγκόσμιο μοντέλο χωρίς να εκτίθενται ευαίσθητες πληροφορίες, ελαχιστοποιώντας έτσι τους κινδύνους προστασίας της ιδιωτικής ζωής. Επιπλέον, η ενσωμάτωση υποδομών υπολογιστών ακμής έχει ενισχύσει σημαντικά τη δυνατότητα εφαρμογής των μεθοδολογιών FL. Οι διακομιστές ακραίων υπολογιστών, που διαθέτουν σημαντικές υπολογιστικές δυνατότητες, διευκολύνουν την αποτελεσματική εκτέλεση των εργασιών FL, επιτρέποντας την τοπική επεξεργασία σε κοντινή απόσταση από τις πηγές δεδομένων. Κατά συνέπεια, το FL αξιοποιεί τη σύγκλιση των αρχών της κατανεμημένης μάθησης και των εξελίξεων στον υπολογισμό ακμών για να παρέχει ένα ισχυρό πλαίσιο για τη συνεργατική εκπαίδευση μοντέλων, διασφαλίζοντας παράλληλα την ιδιωτικότητα των δεδομένων.



Εικόνα 2: Model weights exchange between the central server and the clients in a Federated Learning system

2.3.2 Εφαρμογές του Federated Learning σε Ενεργειακά Συστήματα

Παρόλο που το FL αποτελεί μια σημαντική απομάκρυνση από τα παραδοσιακά κεντρικά συστήματα μηχανικής μάθησης προς ένα ασφαλές και καταναμημένο πλαίσιο, μόνο ένας περιορισμένος αριθμός μελετών έχει εφαρμόσει το FL στον τομέα των σύγχρονων ενεργειακών συστημάτων. Το [35] πρωτοπορεί στην εφαρμογή της FL στην ηλιακή πρόβλεψη, δίνοντας έμφαση στις δυνατότητές της σε καταναμημένα περιβάλλοντα, εντοπίζοντας τους extractors και εκπαιδεύοντας παράλληλα τους forecasters. Αντίθετα, το [36] εξετάζει Behind-the-meter solar forecasting στο πλαίσιο της FL, κάνοντας σύγκριση μεταξύ των centralized, decentralized, και localized forecasting μοντέλων και αναλύοντας λεπτομερώς το trade-off μεταξύ ακρίβειας και ιδιωτικότητας. Σε διαφορετική κατεύθυνση το [37] διερευνά τις χωροχρονικές πτυχές της φωτοβολταϊκής παραγωγής και την αποτελεσματικότητα της FL στην υπερβραχυπρόθεσμη πρόβλεψη. Συσχετίζει τα τοπικά χρονικά χαρακτηριστικά και τα παγκόσμια χωρικά χαρακτηριστικά για την επίτευξη πρόβλεψης ισχύος. Στο [38] παρουσιάζεται ένα μοντέλο πρόβλεψης με κυβερνοασφάλεια που αποτυπώνεται ως Federated Deep Learning. Στόχος είναι τόσο η διαφύλαξη του απορρήτου των δεδομένων, όσο και η βέλτιστη απόδοση έναντι κυβερνοεπιθέσεων, καθώς η μελέτη αφορά περιοχές στο Ιράν. Ενώ αυτές οι μελέτες υπογραμμίζουν συλλογικά την υπόσχεση της FL για την ενίσχυση της ακρίβειας των προβλέψεων φωτοβολταϊκών συστημάτων και τη διατήρηση της ιδιωτικότητας των δεδομένων, οι προκλήσεις όπως η υπολογιστική επιβάρυνση και η αλγοριθμική επιλογή παραμένουν ως ζήτημα για περαιτέρω διερεύνηση.

2.3.3 Προκλήσεις και Ερευνητική Προσέγγιση

Όλες οι παραπάνω έρευνες καθώς και όσες έχουν διεξαχθεί ανά τα χρόνια στον τομέα πρόβλεψης ενέργειας με χρήση του Federated Learning έχουν συμβάλλει ουσιαστικά στην κατανόηση και την επιστημονική διεύρυνση του κλάδου. Εν τούτοις, ελάχιστες είναι οι μελέτες που αναφέρονται στην εφαρμογή και την σύγκριση διαφόρων στρατηγικών FL. Το παρόν ερευνητικό έργο αφορά την εφαρμογή έξι (6) διακριτών στρατηγικών FL, οι οποίες υποβάλλονται σε διαδικασία σύγκρισης προκειμένου να αναδειχθούν οι αντίστοιχες αποτελεσματικότητες τους. Στόχος είναι η διατήρηση της ιδιωτικότητας για την πρόβλεψη της ηλεκτρικής ενέργειας και παράλληλα η αποσαφήνιση της αποτελεσματικότητας των διαφορετικών στρατηγικών, ώστε να γίνει κατανοητή η συμβολή του FL στον τομέα της πρόβλεψης ενέργειας, προσφέροντας έτσι σημαντική προσθήκη στο επιστημονικό κορμό γνώσης.

Θα υλοποιηθεί λοιπόν ένα νευρωνικό δίκτυο LSTM που χρησιμοποιεί την τεχνική του Federated Learning για την πρόβλεψη της φωτοβολταϊκής ενέργειας και ισχύος. Θα εφαρμοστούν έξι (6) διαφορετικές στρατηγικές και θα γίνει εκτενής ανάλυση των αποτελεσμάτων προκειμένου να γίνει αντιληπτή η συμπεριφορά της κάθε στρατηγικής στα παραπάνω πλαίσια.

2.4 Ιστορία και Σχεδιασμός του LSTM Μοντέλου

2.4.1 Ορισμός του Long Short-Term Memory (LSTM) και Ιστορική Αναδρομή

Long Short-Term Memory (LSTM) είναι ένας τύπος αρχιτεκτονικής των recurrent neural network (RNN) που σχεδιάστηκε για να ξεπεράσει τους περιορισμούς των παραδοσιακών RNN στην καταγραφή και αξιοποίηση των μακροπρόθεσμων εξαρτήσεων σε διαδοχικά δεδομένα. Η σχετική αναληψία του στο μήκος του κενού είναι το πλεονέκτημά του έναντι άλλων RNNs. Το όνομα του (μακρά βραχυπρόθεσμη μνήμη) προήλθε από τον σκοπό για τον οποίο δημιουργήθηκε, δηλαδή να παρέχει βραχυπρόθεσμη μνήμη για πολλές χιλιάδες χρονικά βήματα. Παρουσιάστηκε από τους Hochreiter & Schmidhuber την χρονική περίοδο 1995-1997 σε διάφορα άρθρα και έκτοτε έχει γίνει μια από τις πιο δημοφιλείς και αποτελεσματικές αρχιτεκτονικές για εργασίες επεξεργασίας διαδοχικών δεδομένων, όπως η πρόβλεψη χρονοσειρών, η αναγνώριση ομιλίας και η μοντελοποίηση γλωσσικών μοντέλων [39].

2.4.2 Βασικές Αρχές και Λειτουργία του LSTM

Ακολουθεί μια εκτενής ανάλυση του τρόπου λειτουργίας του LSTM:

Μια μονάδα LSTM αποτελείται από μια διάταξη κελιών (cell state) (η "μνήμη" του δικτύου), πύλη εισόδου (input gate), πύλη λήθης (forget gate), πύλη εξόδου (output gate) και προαιρετικές συνδέσεις μεταξύ των κελιών που ονομάζονται "peerhole connections". Η διάταξη των κελιών διατρέχει ολόκληρη την αλυσίδα των μονάδων LSTM, με μικρές μόνο γραμμικές αλληλεπιδράσεις, επιτρέποντας έτσι να παραμείνει αμετάβλητη η ροή πληροφοριών. Κάθε πύλη είναι σαν ένας διακόπτης που ρυθμίζει τη ροή της πληροφορίας μέσα και έξω από την διάταξη. Πιο συγκεκριμένα, η πύλη εισόδου καθορίζει ποια μέρη της εισόδου θα πρέπει να αποθηκευτούν στο cell state. Η πύλη λήθης αποφασίζει ποιες πληροφορίες πρέπει να απορριφθούν από την διάταξη και επομένως αφαιρεί επιλεκτικά τις πληροφορίες που δεν είναι πλέον σχετικές ή χρήσιμες για το τρέχον πλαίσιο. Τέλος η πύλη εξόδου ρυθμίζει τη ροή των πληροφοριών από το cell state στην έξοδο και αποφασίζει ποια μέρη της κατάστασης του κελιού θα πρέπει να εμφανιστούν ως έξοδος της μονάδας LSTM.

Μια λεπτομερής περιγραφή της διαδικασίας της λειτουργίας του LSTM μπορεί να είναι η εξής:

- Σε κάθε χρονικό βήμα, η μονάδα LSTM λαμβάνει μια είσοδο x_t , το προηγούμενο cell state c_{t-1} , και την κρυφή κατάσταση h_{t-1} .
- Η πύλη εισόδου i_t , η πύλη λήθης f_t και η πύλη εξόδου o_t υπολογίζονται με βάση την τρέχουσα είσοδο και την προηγούμενη κρυφή κατάσταση.
- Υπολογίζεται το υποψήφιο cell state \tilde{c}_t , το οποίο είναι υποψήφιο για την ενημέρωση του τρέχοντος state.
- Το cell state c_t ενημερώνεται συνδυάζοντας το υποψήφιο cell state με το προηγούμενη cell state, ελεγχόμενο από τις πύλες εισόδου και λήθης.
- Η κρυφή κατάσταση h_t υπολογίζεται με βάση την ενημερωμένη κατάσταση και την πύλη εξόδου.

Προκειμένου να γίνει πιο κατανοητή η παραπάνω διαδικασία, παρουσιάζονται στη συνέχεια οι μαθηματικές εξισώσεις που περιγράφουν την λειτουργία μιας τέτοιας μονάδας LSTM:

1. Πύλη Λήθης (Forget Gate)

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

Όπου:

- f_t είναι η πύλη λήθης την χρονική στιγμή t
- σ είναι η συνάρτηση sigmoid.
- W_f είναι τα βάρη της πύλης λήθης.
- $[h_{t-1}, x_t]$ είναι η συνένωση της προηγούμενης κρυφής κατάστασης h_{t-1} και της εισόδου x_t .
- b_f είναι η μεταβλητή bias της πύλης λήθης.

2. Πύλη Εισόδου (Input Gate):

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

Όπου:

- i_t είναι η πύλη εισόδου τη χρονική στιγμή t .
- W_i είναι τα βάρη της πύλης εισόδου.
- b_i είναι η μεταβλητή bias της πύλης εισόδου.

3. Υποψήφιο Cell State (Candidate Cell State):

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

Όπου:

- \tilde{c}_t είναι το υποψήφιο cell state τη χρονική στιγμή t .
- \tanh είναι η γνωστή συνάρτηση tanh.
- W_c είναι τα βάρη του υποψήφιου cell state.
- b_c είναι η μεταβλητή bias του υποψήφιου cell state.

4. Ενημέρωση Cell State:

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t$$

Όπου:

- c_t είναι το ενημερωμένο cell state τη χρονική στιγμή t .
- c_{t-1} είναι το προηγούμενο cell state.

5. Πύλη Εξόδου (Output Gate):

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

Όπου:

- o_t είναι η πύλη εξόδου τη χρονική στιγμή t .
- W_o είναι τα βάρη της πύλης εξόδου.
- b_o είναι η μεταβλητή bias της πύλης εξόδου.

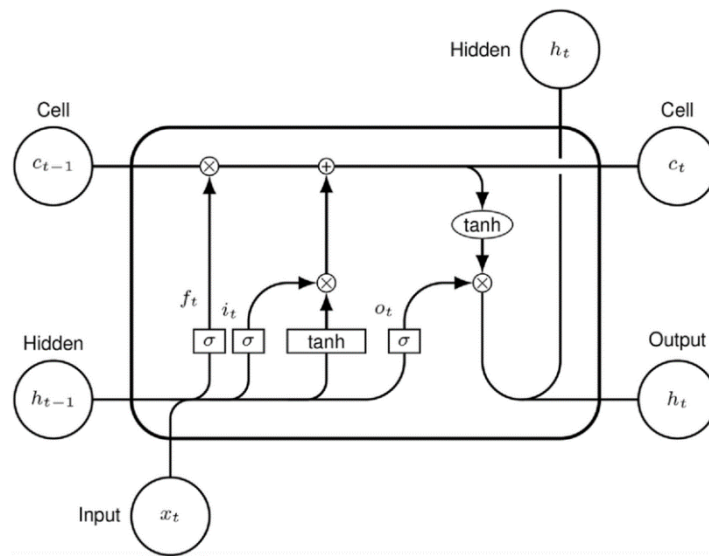
6. Υπολογισμός της Κρυφής Κατάστασης (Hidden State):

$$h_t = o_t \cdot \tanh(c_t)$$

Όπου:

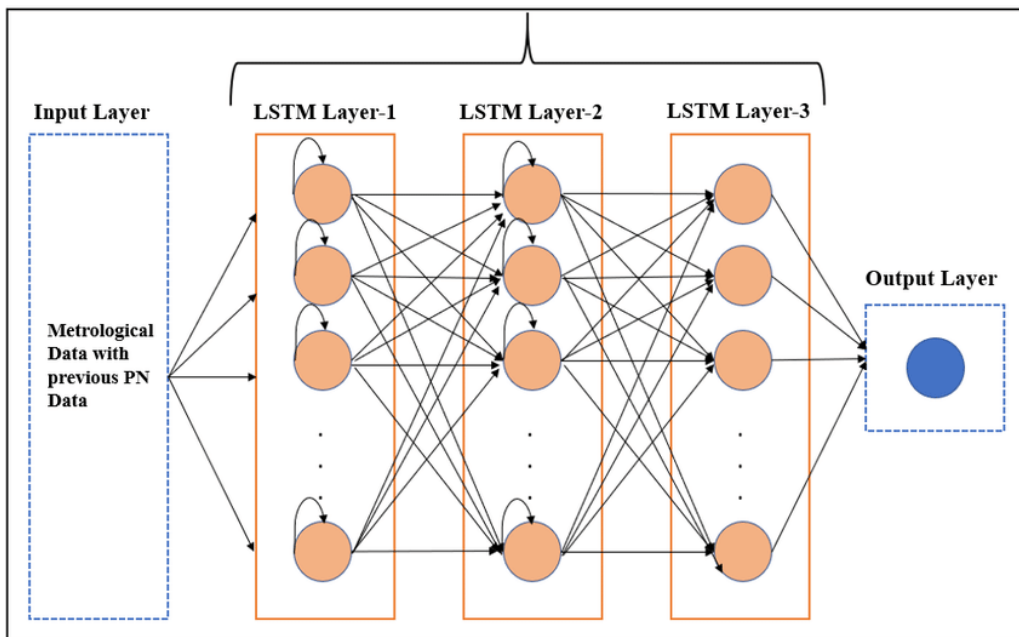
- h_t είναι η κρυφή κατάσταση τη χρονική στιγμή t .

Η μονάδα LSTM χρησιμοποιεί αυτές τις εξισώσεις για να διατηρεί πληροφορίες μέσω της αλυσίδας των χρονικών στιγμών, επιτρέποντας τη ροή των σημαντικών δεδομένων ενώ φιλτράρει τις άσχετες πληροφορίες. Οι συνδέσεις peephole (αν χρησιμοποιούνται) επιτρέπουν στις πύλες να έχουν πρόσβαση στο cell state απευθείας, παρέχοντας πρόσθετη πληροφορία για τη ρύθμιση των πυλών.



Εικόνα 3: The Long Short-Term Memory (LSTM) Cell Structure [79]

Όσον αφορά την παρούσα εργασία, την είσοδο αποτελούν τα ιστορικά δεδομένα που περιγράφουν τις καιρικές συνθήκες καθώς και τα έως τώρα δεδομένα παραγωγής ισχύος. Χρησιμοποιείται, λοιπόν, ένα πλήθος εισόδων από δεδομένα, όπως αυτά παρουσιάστηκαν παραπάνω και διευθετείται η δομή του LSTM ορίζοντας τους αριθμούς που περιγράφουν τα πλήθη των κρυφών καταστάσεων και το πλήθος των συνδεδεμένων στρωμάτων από κελιά που περιέχονται σε αυτό. Τα τελευταία πλήρως συνδεδεμένα στρώματα μετατρέπουν την έξοδο του LSTM στην πρόβλεψη της φωτοβολταϊκής ισχύος.



Εικόνα 4: The Long Short-Term Memory (LSTM) Model Architecture [80]

3 Σχετικές Έρευνες

Η βραχυπρόθεσμη πρόβλεψη της φωτοβολταϊκής ισχύος (Short-term photovoltaic (PV) power forecasting) αποτελεί καθοριστικό παράγοντα για την εκμετάλλευση της ηλιακής ενέργειας από τα δίκτυα ηλεκτρικής ενέργειας. Η διαθεσιμότητα ακριβών προβλέψεων και η παροχή τους στους διαχειριστές δικτύων και ενέργειας, συμβάλλει στην εξισορρόπηση της προσφοράς και της ζήτησης, στη μείωση της εξάρτησης από τα ορυκτά καύσιμα και στην ενίσχυση της σταθερότητας του δικτύου. Για την βελτιστοποίηση των μοντέλων πρόβλεψης, το Federated Learning (FL) έχει αναδειχθεί σε μια από τις πιο πολλά υποσχόμενες προσεγγίσεις, καθώς αξιοποιεί δεδομένα από ποικίλες πηγές, ενώ ταυτόχρονα διατηρεί το απόρρητο των δεδομένων. Παρακάτω γίνεται αναφορά σε παραδείγματα και βιβλιογραφία που αφορούν την βραχυπρόθεσμη πρόβλεψη ισχύος φωτοβολταϊκών συστημάτων και την εφαρμογή του FL σε αυτόν τον τομέα.

3.1 Βραχυπρόθεσμη Πρόβλεψη Φωτοβολταϊκής Ισχύος

3.1.1 Παραδοσιακές Μέθοδοι

Η παραδοσιακή προσέγγιση για την πρόβλεψη της φωτοβολταϊκής ισχύος έχει βασιστεί στα φυσικά μοντέλα και τις στατιστικές μεθόδους. Για να εξομοιώσουν την παραγωγή ηλιακής ενέργειας και να εξάγουν αποτελέσματα, οι φυσικές μέθοδοι χρησιμοποιούν τις καιρικές παραμέτρους και τα χαρακτηριστικά του φωτοβολταϊκού συστήματος. Για παράδειγμα, οι Lorenz κ.ά. (2009) [40] ανέπτυξαν ένα φυσικό μοντέλο που συνδυάζει αριθμητικές προβλέψεις καιρού με τις προδιαγραφές του φωτοβολταϊκού συστήματος για την πρόβλεψη της παραγωγής ηλιακής ισχύος. Οι στατιστικές μέθοδοι, συμπεριλαμβανομένων των αυτοπαλινδρομικών ολοκληρωμένων κινητών μέσων όρων (ARIMA) και των μηχανών διανυσμάτων υποστήριξης (SVM), έχουν επίσης εφαρμοστεί σε μεγάλο βαθμό. Οι Bacher κ.ά. (2009) [41] πρότειναν μια προσέγγιση με βάση τον ARIMA για βραχυπρόθεσμη πρόβλεψη ισχύος φωτοβολταϊκών συστημάτων, επιδεικνύοντας σημαντικές βελτιώσεις σε σχέση με τα μοντέλα εμμονής. Ομοίως, οι Chen et al. (2011) [42] εφάρμοσαν SVM για την πρόβλεψη της φωτοβολταϊκής παραγωγής, τονίζοντας την ικανότητα του μοντέλου να συλλαμβάνει μη γραμμικές σχέσεις στα δεδομένα.

3.1.2 Μέθοδοι Μηχανικής Μάθησης

Η ραγδαία εξέλιξη της υπολογιστικής τεχνολογίας, επέτρεψε την έλευση της μηχανικής μάθησης στον τομέα πρόβλεψης ηλεκτρικής ισχύος. Συγκεκριμένα, τα νευρωνικά δίκτυα αναπτύσσονται ταχύρρυθμα και έχουν ήδη εδραιώσει την θέση τους σε αυτό τον κλάδο, ιδίως τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN) και τα δίκτυα μακράς βραχυπρόθεσμης μνήμης (LSTM). Οι Sleiman A. και Wencong Su [43] χρησιμοποίησαν το μοντέλο LSTM για την πρόβλεψη ισχύος, αξιοποιώντας ποικίλες παραμέτρους, επιτυγχάνοντας μέσο απόλυτο σφάλμα (MAE) 5,7% μεταξύ του πραγματικού και του προβλεπόμενου φορτίου παραγωγής. Απήχηση στον ερευνητικό κλάδο έχουν επίσης οι μηχανές ενίσχυσης κλίσης (GBMs). Οι Necati Aksoy και Istemihan Genc [44] χρησιμοποίησαν GBMs για βραχυπρόθεσμη πρόβλεψη ισχύος επισημαίνοντας και τονίζοντας την γρήγορη προσαρμογή και την υψηλή ακρίβεια του μοντέλου.

3.2 Federated Learning

3.2.1 Εφαρμογές στον Ενεργειακό Τομέα

Το Federated Learning (FL) είναι μια αποκεντρωμένη προσέγγιση μηχανικής μάθησης, που αναλύεται εκτενώς σε άλλα κεφάλαια της παρούσας εργασίας και όπως παρουσιάζεται από τους McMahan κ.ά. (2017) [45] είναι ικανή να αντιμετωπίσει για την προστασία της ιδιωτικότητας των δεδομένων, να μειώσει το κόστος επικοινωνίας και αξιοποιήσει καταναμημένες πηγές δεδομένων. Το FL έχει δοκιμαστεί σε διάφορες εφαρμογές που σχετίζονται με την ενέργεια. Για παράδειγμα, οι Yang κ.ά. (2019) [46] εφάρμοσαν το FL για τη διαχείριση της ζήτησης σε έξυπνα δίκτυα, επιδεικνύοντας βελτιωμένη ακρίβεια πρόβλεψης φορτίου και διατηρώντας παράλληλα την ιδιωτικότητα των χρηστών. Ομοίως, οι Qian et al. (2023) [47] αξιοποίησαν το FL για την πρόβλεψη της ζήτησης φόρτισης ηλεκτρικών οχημάτων, αναδεικνύοντας την αποτελεσματικότητα της μεθόδου στον χειρισμό της ποικιλομορφία της στρατηγικής ελέγχου φόρτισης, τις διακυμάνσεις ισχύος στο RDN (radial distribution network) και την αποδοτικότητα σύγκλισης.

3.2.2 Εφαρμογές στην Πρόβλεψη Φωτοβολταϊκής Ισχύος

Το FL έχει εφαρμοστεί όμως και στην πρόβλεψη της φωτοβολταϊκής ισχύος. Οι Wen κ.ά. (2022) [48] πρότειναν ένα FL framework για τη βραχυπρόθεσμη πρόβλεψη ισχύος, κάνοντας χρήση δεδομένων από δέκα (10) φωτοβολταϊκούς σταθμούς και συγκρίνοντας τις τεχνικές FL που δοκίμασαν με συγκεντρωτικές και τοπικές μεθόδους. Τα αποτελέσματα έδειξαν ότι το Federated Learning υπερτερεί των άλλων μοντέλων σε ακρίβεια και η απόδοση των υπολοίπων μπορεί να

βελτιωθεί σημαντικά με τη χρήση του FL, ενώ παράλληλα διατηρείται το απόρρητο των δεδομένων. Σε μια άλλη έρευνα, οι Wang κ.ά. (2023) [49] σχεδίασαν ένα υβριδικό μοντέλο πρόβλεψης που ενσωματώνει το Federated Learning στη συνένωση τεχνικών βαθιάς μάθησης. Συγκεκριμένα, συνδυάζονται ένα LSTM με ένα BPNN τα οποία χρησιμοποιούνται για την εξαγωγή σημαντικών χαρακτηριστικών από τα δεδομένα χρονοσειρών και την χαρτογράφηση των εξαγόμενων χαρακτηριστικών υψηλής διάστασης στον χώρο χαμηλής διάστασης, αντίστοιχα. Με την χρήση του FL στο παραπάνω μοντέλο, επιτυγχάνεται πάνω από 20% βελτίωση στην ακρίβεια, ενώ το μοντέλο αποκτά την δυνατότητα γενίκευσης σε πολλαπλά σενάρια.

3.3 Ευρήματα Ανασκόπησης των Σχετικών Ερευνών

Η χρήση των παραδοσιακών μεθόδων και των τεχνικών μηχανικής μάθησης στην βραχυπρόθεσμη πρόβλεψη φωτοβολταϊκής ισχύος έχει συντελέσει καθοριστικά σε αυτό τον κλάδο. Ωστόσο, το Federated Learning παρέχει νέες δυνατότητες, επιτρέποντας τη συνεργατική εκπαίδευση μοντέλων σε καταναμημένες πηγές δεδομένων, ενώ παράλληλα διατηρεί το απόρρητο των δεδομένων. Πολλές από τις προκλήσεις για την ακρίβεια των αποτελεσμάτων εξακολουθούν να παραμένουν, όμως η διαρκής έρευνα σε συνδυασμό με την συνεχή πρόοδο της τεχνολογίας επιτρέπουν την προσέγγιση και την δημιουργία μοντέλων με υψηλότερη ακρίβεια και ασφάλεια στην πρόβλεψη φωτοβολταϊκής ισχύος.

Για τους παραπάνω λόγους, το παρόν ερευνητικό έργο αναλαμβάνει τη μελέτη της πρόβλεψης ενέργειας φωτοβολταϊκών συστημάτων μέσω της τεχνικής του Federated Learning (FL). Η καινοτομία του προτεινόμενου πλαισίου ανακλά την εφαρμογή έξι (6) διακριτών στρατηγικών FL, οι οποίες υποβάλλονται σε διαδικασία σύγκρισης προκειμένου να αναδειχθούν οι αντίστοιχες αποτελεσματικότητες. Η εκτενής ανάλυση των αποτελεσμάτων αποσκοπεί στην κατανόηση της συμπεριφοράς και της απόδοσης της κάθε στρατηγικής στο πλαίσιο αυτό. Ο μεθοδολογικός σχεδιασμός περιλαμβάνει την προετοιμασία και την εκτέλεση εκτενών πειραμάτων, την ανάλυση των δεδομένων και την ερμηνεία των αποτελεσμάτων. Το έργο στοχεύει στην εμβάθυνση της κατανόησης της συμβολής του FL στον τομέα της πρόβλεψης ενέργειας και στην αποσαφήνιση της αποτελεσματικότητας των διαφορετικών στρατηγικών, προσφέροντας έτσι σημαντική προσθήκη στο επιστημονικό κορμό γνώσης.

4 Παρουσίαση Εργαλείων και Συνόλου Δεδομένων

4.1 Παρουσίαση και Ανάλυση Εργαλείων που Χρησιμοποιήθηκαν

Για την ανάπτυξη και την υλοποίηση της συνολικής εφαρμογής και των πειραμάτων τα οποία πραγματεύεται η εργασία χρησιμοποιήθηκαν ορισμένα βασικά εργαλεία. Η διαδικασία υλοποίησης βασίστηκε στην γλώσσα προγραμματισμού Python που προσφέρει ένα ευέλικτο και ισχυρό βοήθημα για την ανάπτυξη κώδικα, στο PyTorch που είναι απαραίτητο για την χρήση των νευρωνικών δικτύων και σε διάφορες βιβλιοθήκες της Python μερικές από τις οποίες είναι οι Pandas, NumPy, Sci-kit learn και Matplotlib. Σαν περιβάλλον γραφής και ανάπτυξης κώδικα χρησιμοποιήθηκε το Visual Studio Code (VS Code) που αποτελεί έναν ισχυρό code editor με εύρος δυνατοτήτων. Τέλος, αξιοποιήθηκε το Flower, αναγκαίο εργαλείο για την ενσωμάτωση της καινοτομίας του Federated Learning. Τα παραπάνω εργαλεία συμβάλλουν όλα μαζί στην δημιουργία ενός ολοκληρωμένου έργου που αφορά το PV power forecasting με χρήση FL και την διατήρηση της ιδιωτικότητας.

Παρακάτω παρουσιάζονται πιο αναλυτικά τα εργαλεία στα οποία βασίστηκε η παρούσα εργασία:

4.1.1 Γλώσσα Προγραμματισμού Python

Η Python είναι μια υψηλού επιπέδου, διερμηνευμένη γλώσσα προγραμματισμού που φημίζεται για την απλότητα, την αναγνωσιμότητα και την ευελιξία της. Είναι σχεδιασμένη για αντικειμενοστραφή προγραμματισμό και το συντακτικό της δίνει βαρύτητα στη σαφήνεια του κώδικα και την ευκολία χρήσης, διευκολύνοντας την ανάπτυξη εφαρμογών καθώς μειώνεται η πιθανότητα λαθών. Η δυναμική τυποποίηση και η ολοκληρωμένη τυποποιημένη βιβλιοθήκη της, την καθιστούν ιδανική ως συγκολλητική γλώσσα για την σύνδεση υπαρχόντων στοιχείων μεταξύ τους, ενώ υποστηρίζουν ένα ευρύ φάσμα εφαρμογών, από την ανάλυση δεδομένων και τη μηχανική μάθηση μέχρι την ανάπτυξη ιστοσελίδων και την αυτοματοποίηση. Το εκτεταμένο οικοσύστημα βιβλιοθηκών και πακέτων της Python ενθαρρύνει την επαναχρησιμοποίηση του κώδικα και την αρτιότητα των προγραμμάτων. [50]

4.1.2 Pytorch

Το PyTorch είναι ένα πλαίσιο μηχανικής μάθησης ανοικτού κώδικα βασισμένο στην βιβλιοθήκη Torch που αναπτύχθηκε από το εργαστήριο AI Research του Meta και τώρα είναι μέρος του Linux Foundation. Έχει σχεδιαστεί για να διευκολύνει τη

δημιουργία και την εκπαίδευση νευρωνικών δικτύων και χρησιμοποιείται για την κατασκευή μοντέλων βαθιάς μάθησης. Το PyTorch διακρίνεται για την χρήση της αυτόματης διαφοροποίησης αντίστροφης λειτουργίας (automatic differentiation), το autograd, που είναι ζωτικής σημασίας για το backpropagation στα νευρωνικά δίκτυα. Είναι γνωστό, επίσης, για την εξαιρετική υποστήριξη του στην εκπαίδευση νευρωνικών δικτύων με την ομαλή επιτάχυνση που επιτυγχάνει στην χρήση των γραφικών μονάδων επεξεργασίας (GPUs) για αποδοτικούς υπολογισμούς. [51] [52] [53] [54]

4.1.3 Βιβλιοθήκες Pandas, NumPy, Scikit-learn και Matplotlib

Το πλούσιο οικοσύστημα των βιβλιοθηκών της Python είναι αυτό που σε ένα μεγάλο βαθμό την έχει καταστήσει μία από τις κυρίαρχες γλώσσες στους τομείς της επιστήμης των δεδομένων, της μηχανικής μάθησης, καθώς διευκολύνει πολύπλοκες διεργασίες με απλότητα και αποτελεσματικότητα. Μεταξύ αυτών των βιβλιοθηκών, οι Pandas, NumPy, Scikit-learn και Matplotlib είναι αυτές που εξυπηρέτησαν την παρούσα εργασία και είναι υπεύθυνες για τον χειρισμό δεδομένων, τους αριθμητικούς υπολογισμούς, τη μηχανική μάθηση και την οπτικοποίηση δεδομένων, αντίστοιχα. Κάθε βιβλιοθήκη εξυπηρετεί το δικό της σκοπό και έχει τη δική της χρησιμότητα και όλες μαζί συμβάλλουν ουσιαστικά στην ροή εργασίας και την επίτευξη ενός επιστημονικού έργου.

- Pandas

Το Pandas είναι μια ισχυρή βιβλιοθήκη ανοικτού κώδικα που έχει σχεδιαστεί για την επεξεργασία και την ανάλυση δεδομένων, γραμμένη για τη γλώσσα προγραμματισμού Python. Παρέχει δομές δεδομένων, όπως Series και DataFrame, οι οποίες είναι κατάλληλες για τον χειρισμό αριθμητικών πινάκων και χρονοσειρών, αλλά και γενικότερα δομημένων δεδομένων. Η βιβλιοθήκη Pandas σχεδιάστηκε ως ένα υψηλού επιπέδου εργαλείο για την διεξαγωγή πολύ πρακτικών αναλύσεων στον πραγματικό κόσμο στην γλώσσα προγραμματισμού Python, καθώς παρέχει ένα ευρύ φάσμα λειτουργιών δεδομένων, όπως καθαρισμός, μετασχηματισμός, συγχώνευση και συνάθροιση δεδομένων. Έλαβε το όνομα της από την φράση «panel data» που αποτελεί όρο της οικονομετρίας και αφορά σύνολα δεδομένων που περιλαμβάνουν παρατηρήσεις για πολλαπλές χρονικές περιόδους. [55] [56] [57]

- NumPy

Η NumPy που έχει σαν πλήρη ονομασία τον όρο Numerical Python, είναι η θεμελιώδης, δωρεάν βιβλιοθήκη ανοικτού κώδικα για αριθμητικούς και

επιστημονικούς υπολογισμούς στην γλώσσα προγραμματισμού Python. Δίνει την δυνατότητα στην Python να μπορεί να φιλοξενήσει μεγάλους, πολυδιάστατους πίνακες, τους ndarrays, που επιτρέπουν γρήγορους και αποδοτικούς υπολογισμούς. Παρέχει επίσης μια συλλογή μαθηματικών συναρτήσεων και πράξεων υψηλού επιπέδου που λειτουργούν σε συνδυασμό με αυτούς τους πίνακες. Οι μαθηματικές συναρτήσεις αυτές διευκολύνουν τομείς όπως βασική γραμμική άλγεβρα, τυχαία προσομοίωση, μετασχηματισμοί Fourier, τριγωνομετρικές πράξεις και στατιστικές πράξεις. Είναι ευρέως γνωστή για την βελτιστοποίηση μαθηματικών πράξεων και βιβλιοθήκες όπως οι Pandas, Scikit-learn και SciPy συνεργάζονται άψογα με την NumPy και γι' αυτό αποτελεί βασικό συστατικό της Python. [58] [59] [60]

- Scikit-learn

Η Scikit-learn ή sklearn όπως είναι επίσης δημοφιλής, είναι μια ευέλικτη, δωρεάν και ανοικτού κώδικα βιβλιοθήκη μηχανικής μάθησης που βασίζεται στις NumPy, SciPy και Matplotlib και έχει σχεδιαστεί για την γλώσσα προγραμματισμού Python. Προσφέρει ένα ευρύ φάσμα αλγορίθμων για ταξινόμηση, παλινδρόμηση, ομαδοποίηση και μείωση διαστάσεων, καθιστώντας το κατάλληλο τόσο για ακαδημαϊκή έρευνα όσο και για βιομηχανικές εφαρμογές. Οι αλγόριθμοι συμπεριλαμβάνουν μηχανές διανυσμάτων υποστήριξης, δάση βροχής, gradient boosting, k-means και DBSCAN. Διαθέτει επίσης εργαλεία για οπτικοποιήσεις ML, προεπεξεργασία, προσαρμογή, επιλογή και αξιολόγηση μοντέλων. Το Scikit-learn με την εκτεταμένη συλλογή εργαλείων και αλγορίθμων που διαθέτει, αποτελεί την κατάλληλη βιβλιοθήκη για την υλοποίηση και τον πειραματισμό με μοντέλα μηχανικής μάθησης. [61] [62] [63]

- Matplotlib

Η Matplotlib είναι μια ολοκληρωμένη βιβλιοθήκη για τη δημιουργία στατικών, κινούμενων και διαδραστικών απεικονίσεων για τη γλώσσα προγραμματισμού Python. Οι χρήστες μπορούν να δημιουργήσουν μια μεγάλη ποικιλία γραφικών παραστάσεων, από απλά γραμμικά γραφήματα και ιστογράμματα μέχρι σύνθετες τρισδιάστατες απεικονίσεις. Η Matplotlib παρέχει ένα αντικειμενοστραφές API για την ενσωμάτωση γραφικών παραστάσεων σε εφαρμογές που χρησιμοποιούν εργαλειοθήκες GUI γενικού σκοπού όπως το Tkinter, το wxPython, το Qt ή το GTK. Η ευελιξία της και οι επιλογές προσαρμογής της, την καθιστούν απαραίτητο εργαλείο για την εξερεύνηση και την παρουσίαση δεδομένων. [64] [65]

Αναλύθηκαν παραπάνω οι λειτουργίες και η χρησιμότητα των βιβλιοθηκών Pandas, NumPy, Scikit-learn και Matplotlib για την κάθε βιβλιοθήκη ξεχωριστά. Όλες μαζί όμως αποτελούν μια ισχυρή εργαλειοθήκη που επιτρέπει τον αποτελεσματικό χειρισμό δεδομένων, τον αριθμητικό υπολογισμό, τη μηχανική μάθηση και την οπτικοποίηση στη γλώσσα προγραμματισμού Python. Η χρήση τους όχι μόνο απλοποιεί την ροή εργασίας σε μια εργασία, αλλά δίνει και την δυνατότητα για άντληση σημαντικών γνώσεων και την δημιουργία εξελιγμένων μοντέλων με ευκολία. Η εκμάθηση τους επιτρέπει την αξιοποίηση της δυναμικότητας της Python για την ανακάλυψη και την καινοτομία με γνώμονα τα δεδομένα.

4.1.4 Visual Studio Code (VS Code)

Το Visual Studio Code γνωστό και ως VS Code είναι ένα προϊόν που ανέπτυξε η Microsoft για την επεξεργασία πηγαίου κώδικα και έχει αποκτήσει ευρεία αποδοχή για την ευελιξία του, τις επιδόσεις του και το εύρος των δυνατοτήτων του. Είναι επεξεργαστής κώδικα σχεδιασμένος να λειτουργεί σε Windows, macOS, Linux και προγράμματα περιήγησης στο διαδίκτυο και υποστηρίζει ένα ευρύ φάσμα γλωσσών προγραμματισμού και πλαϊσίων μέσω της εκτεταμένης βιβλιοθήκης επεκτάσεων που διαθέτει. Τα βασικά χαρακτηριστικά περιλαμβάνουν IntelliSense για έξυπνη συμπλήρωση κώδικα και ανίχνευση σφαλμάτων, ενσωματωμένο Git για απρόσκοπτο έλεγχο εκδόσεων, ενσωματωμένο τερματικό και ισχυρές δυνατότητες αποσφαλμάτωσης και υπογράμμισης συντακτικού. Επιπλέον, το εξαιρετικά παραμετροποιήσιμο περιβάλλον εργασίας του επιτρέπει στους προγραμματιστές να προσαρμόζουν τον επεξεργαστή στις συγκεκριμένες ανάγκες της ροής εργασίας τους αλλάζοντας θέμα, συντομεύσεις πληκτρολογίου και εγκαθιστώντας συντομεύσεις. Αυτά τα χαρακτηριστικά καθιστούν το Visual Studio Code ένα ανεκτίμητο εργαλείο, διευκολύνοντας την αποτελεσματική κωδικοποίηση, τη συνεργασία και τη διαχείριση έργων σε διάφορους τομείς μελέτης. Αυτός είναι και ο λόγος που αποτελεί και ένα από τα πιο δημοφιλή εργαλεία περιβάλλοντος ανάπτυξης και προτιμάτε από τους χρήστες ανά τον κόσμο. [66] [67]

4.1.5 Flower A Friendly Federated Learning Framework

Το Flower είναι ανοικτού κώδικα πλαίσιο Federated Learning που έχει σχεδιαστεί για να διευκολύνει την έρευνα και την ανάπτυξη στον τομέα του Federated Learning. Βασιζόμενο στην Python είναι ένα φιλικό προς τον χρήστη πλαίσιο και αποσκοπεί στην εκπαίδευση ενός ευρέος φάσματος μοντέλων, συμπεριλαμβανομένων των βαθιών νευρωνικών δικτύων (deep neural networks). Παρέχει μια ευέλικτη πλατφόρμα και επιτρέπει την ενσωμάτωση σε υπάρχουσες ροές εργασίας, αφού υποστηρίζει διάφορα πλαίσια μηχανικής μάθησης, όπως το

TensorFlow, το PyTorch και το Keras. Το βασικό πλεονέκτημα του Flower έγκειται στην απλοποίηση της διαδικασίας υλοποίησης εργασιών Federated Learning. Διαδικασίες όπως η κατάτμηση δεδομένων και μοντέλων, η επικοινωνία μεταξύ συσκευών και ο μέσος όρος των μοντέλων που αποτελούν περίπλοκες τεχνικές λεπτομέρειες καλύπτονται από το API, δίνοντας την δυνατότητα στον χρήστη να αναλάβει αυξημένης δυσκολίας εργασίες Federated Learning χωρίς ιδιαίτερο κόπο, αφού του επιτρέπει να επικεντρωθεί στις ιδιαιτερότητες των εργασιών. Επιπλέον η προσαρμοστικότητα που διέπει την αρχιτεκτονική του Flower δίνει την δυνατότητα χειρισμού βασικών στοιχείων συμπεριλαμβανομένης της επιλογής πελάτη, των στρατηγικών συγκέντρωσης και των πρωτοκόλλων επικοινωνίας, καθιστώντας το ευέλικτο για ποικίλα σενάρια εργασιών Federated Learning. Ενσωματώνοντας αρχιτεκτονική πελάτη-εξυπηρετητή, το Flower χρειάζεται μια ελάχιστη διαμόρφωση ενός διακομιστή και τουλάχιστον δύο πελατών ώστε να είναι εφικτή η έναρξη της εκπαίδευσης. Τέλος για να ενισχύσει την ιδιωτικότητα και την ασφάλεια των δεδομένων, εξασφαλίζει τη συνεργατική εκπαίδευση μοντέλων σε πολλαπλούς πελάτες χωρίς τον διαμοιρασμό τοπικών δεδομένων καθιστώντας το ιδανική επιλογή για εφαρμογές στην υγειονομική περίθαλψη, τα χρηματοοικονομικά, το IoT και τις τηλεπικοινωνίες. [68] [69]

4.1.6 Συμπεράσματα

Εν κατακλείδι, το σύνολο των εργαλείων που χρησιμοποιήθηκαν και η μεταξύ τους αλληλεπίδραση ήταν καθοριστική για την ομαλή ροή της έρευνας στον τομέα του Federated Learning. Η ευελιξία και η ευκολία χρήσης της Python επέτρεψαν την ταχεία ανάπτυξη και δοκιμή των αλγορίθμων. Το PyTorch παρείχε την απαραίτητη υποδομή βαθιάς μάθησης, καθιστώντας εφικτή την κατασκευή και την βελτιστοποίηση πολύπλοκων νευρωνικών δικτύων, ενώ σε συνεργασία με τις βιβλιοθήκες Pandas, NumPy, Scikit-learn και Matplotlib ήταν δυνατή η διαχείριση του όγκου δεδομένων και η κατάλληλη αξιοποίηση τους. Το Vs Code και οι δυνατότητες επεξεργασίας και αποσφαλμάτωσης που διαθέτει, φιλοξένησαν τον κώδικα βελτιώνοντας την παραγωγικότητα και την αποτελεσματικότητά του. Παρείχε ένα αξιόπιστο περιβάλλον και ταυτόχρονα εύκολο στη χρήση. Τέλος, το framework του Flower, παρείχε τις υποδομές για την απροβλημάτιστη υλοποίηση και διαχείριση του συστήματος Federated Learning και διασφάλισε την επεκτασιμότητα και την επαναληψιμότητα των πειραμάτων. Σε συνδυασμό, αυτά τα εργαλεία όχι μόνο απλοποίησαν τη ροή εργασίας, αλλά συνέβαλαν επίσης σημαντικά στην ευρωστία και την επιτυχία των ερευνητικών προσπαθειών στον τομέα του Federated Learning.

4.1.7 Εκδόσεις εργαλείων και τεχνικά χαρακτηριστικά υπολογιστή

Για την διεξαγωγή και την ολοκλήρωση των πειραμάτων της εργασίας χρησιμοποιήθηκε:

- Python 3.9.1,
- Pytorch 2.0.1,
- Flower 1.4.0,
- Visual Studio Code version 1.90.0

Το Flower αρχικοποιήθηκε με χαρακτηριστικά: {'CPU': 12.0, 'node:127.0.0.1': 1.0, 'memory': 4186447872.0, 'GPU': 1.0, 'object_store_memory': 2093223936.0}.

Χρησιμοποιήθηκε για την πραγματοποίηση των πειραμάτων προσωπικός ηλεκτρονικός υπολογιστής (Personal Computer) με:

- Λειτουργικό σύστημα Windows 10 Pro,
- Λειτουργικό σύστημα τεχνολογίας 64 bit,
- 16 GB εγκατεστημένης μνήμης RAM,
- Σκληρό δίσκο χωρητικότητας 1 TB,
- Επεξεργαστή AMD Ryzen 5 2600X Six-Core Processor 3.60 GHz

4.2 Περιγραφή Συνόλου Δεδομένων

Το σύνολο δεδομένων περιλαμβάνει πληροφορίες σχετικές με τη λειτουργία και την απόδοση φωτοβολταϊκών συστημάτων, με στόχο να αναπτυχθούν και να εκπαιδευτούν μοντέλα πρόβλεψης της παραγωγής ενέργειας. Αυτές οι πληροφορίες είναι απαραίτητες για να μπορέσουν τα μοντέλα να συσχετίσουν τις διάφορες συνθήκες λειτουργίας με την απόδοση των φωτοβολταϊκών συστημάτων και, συνεπώς, να προβλέψουν με ακρίβεια την παραγόμενη ενέργεια σε πραγματικό χρόνο.


4.2.1 Φωτοβολταϊκά Συστήματα

Οι φωτοβολταϊκές εγκαταστάσεις από τις οποίες αντλούνται δεδομένα ωριαίας φωτοβολταϊκής παραγωγής είναι επτά (7) στο σύνολο. Τα δεδομένα για την ενέργεια που παράγουν τα φωτοβολταϊκά προέρχονται απευθείας από συστήματα ηλιακών σταθμών μιας πορτογαλικής ενεργειακής κοινότητας, ενώ οι πληροφορίες για τις καιρικές συνθήκες προέρχονται από έναν τοπικό μετεωρολογικό σταθμό και το Copernicus Atmosphere Data Store. Στον πίνακα 1 παρουσιάζονται αναλυτικά στοιχεία για τις αναφερόμενες φωτοβολταϊκούς σταθμούς.

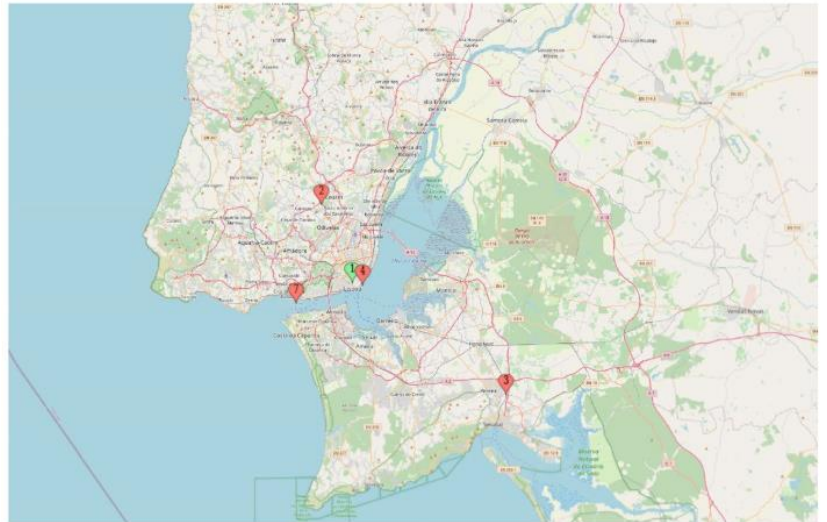
PV	Location	Latitude	Longitude	Nominal(kw)	Peak(kw)	Avail. Data (rows)	From date	To date
PV ₁	Lisbon	38.728	-9.138	23.52	20.00	21956	01/08/2018	31/01/2021
PV ₂	Lisbon	38.833	-9.191	46.00	40.00	21908	01/08/2018	01/01/2021
PV ₃	Setubal	38.577	-8.872	271.53	216.00	9670	02/02/2020	10/03/2021
PV ₄	Lisbon	38.725	-9.120	30.00	27.00	20588	01/08/2018	31/01/2021
PV ₅	Faro	37.031	-7.893	60.48	50.00	15044	09/08/2019	30/04/2021
PV ₆	Braga	41.493	-8.496	119.88	108.00	18045	10/01/2019	31/01/2021
PV ₇	Lisbon	38.701	-9.236	55.65	50.00	21932	01/08/2018	31/01/2021

Πίνακας 1: Πληροφορίες των φωτοβολταϊκών εγκαταστάσεων που χρησιμοποιήθηκαν στις πειραματικές διαδικασίες της παρούσας εργασίας

Τα παραπάνω φωτοβολταϊκά συστήματα είναι τοποθετημένα σε τέσσερις (4) διαφορετικές πόλεις της χώρας της Πορτογαλίας. Συγκεκριμένα έχουν εγκατασταθεί στις πόλεις Λισαβόνα, Φάρο, Μπράγκα και Σετουμπάλ. Όπως φαίνεται και παραπάνω η ονομαστική και η μέγιστη ισχύς των φωτοβολταϊκών ποικίλει με την ονομαστική ισχύ να διαμορφώνεται από την χαμηλότερη 23,52 kW έως την υψηλότερη 271,53 kW. Για να είναι εφικτός ο εντοπισμός πιθανών ανακριβειών στις προβλέψεις που θα εξάγει το μοντέλο, επιλέχθηκαν φωτοβολταϊκοί σταθμοί που είναι εγκατεστημένοι στην ίδια πόλη, όπως οι PV₁, PV₂, PV₄ και PV₇, αλλά και σταθμοί που είναι σε διαφορετικές πόλεις σε σύγκριση με τους υπόλοιπους, όπως PV₃, PV₅ και PV₆. Στον χάρτη φαίνονται και οι τοποθεσίες των φωτοβολταϊκών εγκαταστάσεων (Οι χάρτες δημιουργήθηκαν με το <https://www.mapcustomizer.com>).



Εικόνα 5: Map with the locations of the PV facilities



Εικόνα 6: Map of the city of Lisbon with the locations of four PV facilities

4.2.2 Δεδομένα Φωτοβολταϊκών

Τα δεδομένα των φωτοβολταϊκών περιλαμβάνουν διάφορες μεταβλητές που επηρεάζουν την απόδοση των φωτοβολταϊκών συστημάτων. Χωρίζονται σε μετεωρολογικά δεδομένα, δεδομένα του ίδιου του συστήματος, χρονικές πληροφορίες και γεωγραφικές πληροφορίες (οι γεωγραφικές πληροφορίες παρουσιάστηκαν στο 5.2.1).

- Μετεωρολογικές Παράμετροι

Οι μετεωρολογικές παράμετροι, όπως η ηλιακή ακτινοβολία, η ταχύτητα του ανέμου, καθώς και η σχετική υγρασία, αποτελούν βασικούς παράγοντες που επηρεάζουν την απόδοση των φωτοβολταϊκών πάνελ. Για παράδειγμα, η αυξημένη ηλιακή ακτινοβολία συνήθως οδηγεί σε μεγαλύτερη παραγωγή ενέργειας, ενώ η υψηλή θερμοκρασία μπορεί να μειώσει την απόδοση των πάνελ.

- Δεδομένα Συστήματος

Τα δεδομένα συστήματος περιλαμβάνουν την ισχύ παραγωγής, καθώς και τη θερμοκρασία των πάνελ. Αυτά τα δεδομένα επιτρέπουν την ανάλυση της απόδοσης των φωτοβολταϊκών συστημάτων υπό διάφορες λειτουργικές συνθήκες και βοηθούν στην αναγνώριση πιθανών σημείων βελτίωσης ή προβλημάτων στη λειτουργία τους.

- Χρονικές Πληροφορίες

Οι χρονικές πληροφορίες, όπως η ημερομηνία (ημέρα, μήνας, έτος) και η ώρα καταγραφής, καθώς και οι εποχιακές διακυμάνσεις, προσφέρουν το πλαίσιο για την ανάλυση της απόδοσης των συστημάτων κατά τη διάρκεια διαφορετικών περιόδων. Αυτό είναι ιδιαίτερα σημαντικό για την κατανόηση των εποχιακών τάσεων και τη βελτιστοποίηση της παραγωγής ενέργειας σε μακροπρόθεσμο επίπεδο.

Επομένως το σύνολο δεδομένων περιλαμβάνει ιστορικά δεδομένα πρόβλεψης καιρού και την παραγόμενη φωτοβολταϊκή ισχύ για κάθε ένα φωτοβολταϊκό σύστημα ξεχωριστά.

Συγκεκριμένα περιλαμβάνει τα ακόλουθα χαρακτηριστικά:

- Ηλιακή Ακτινοβολία
- Θερμοκρασία
- Υγρασία
- Ισχύς Παραγωγής των Φωτοβολταϊκών
- Ημερομηνία (ημέρα, μήνα, έτος)
- Ωρα

Τα παραπάνω χαρακτηριστικά παρέχονται από το σύνολο δεδομένων ανά ώρα για όλο το εικοσιτετράωρο. Οι φωτοβολταϊκές εγκαταστάσεις που συμμετέχουν στην εκπαίδευση του μοντέλου πρόβλεψης ισχύος είναι επτά (7) στο σύνολο, όπως προαναφέρθηκε, και συνεπώς ο όγκος των δεδομένων είναι αρκετά μεγάλος, με αποτέλεσμα να υπάρχει ετερογένεια στα δεδομένα.

Όλα τα δεδομένα κανονικοποιούνται μεταξύ των τιμών 0 και 1, χρησιμοποιώντας την συνάρτηση MinMaxScaler (min-max κανονικοποίηση), ενώ η ώρα της ημέρας επιδέχεται μετασχηματισμό ημιτόνου και συνημιτόνου. Παράλληλα τα δεδομένα διαίρονται σε batches των 32 entries και διαρθρώνονται στην κατάλληλη μορφή ακολουθιών 5 εισόδων και μίας εξόδου, ώστε να χρησιμοποιηθούν σαν είσοδος στο μοντέλο μηχανικής μάθησης LSTM (Long Short-Term Memory).

Επιπλέον, η κανονικοποίηση των δεδομένων εξασφαλίζει ότι όλες οι παράμετροι συμβάλλουν ισότιμα στη διαδικασία εκπαίδευσης του μοντέλου, ανεξαρτήτως της αρχικής τους κλίμακας. Η διαίρεση σε batches και η διαμόρφωση των δεδομένων σε ακολουθίες επιτρέπει στο μοντέλο LSTM να μάθει από τα ιστορικά μοτίβα των καιρικών συνθηκών και της παραγόμενης ισχύος, βελτιώνοντας την ικανότητά του να κάνει ακριβείς προβλέψεις για το μέλλον.

Το μοντέλο LSTM είναι ιδιαίτερα κατάλληλο για αυτή την εφαρμογή, καθώς μπορεί να αξιοποιήσει τις χρονικές εξαρτήσεις των δεδομένων, κατανοώντας τις μακροχρόνιες σχέσεις μεταξύ των παραμέτρων. Αυτή η προσέγγιση βοηθά στη βελτίωση της ακρίβειας των προβλέψεων και συμβάλλει στη βέλτιστη εκμετάλλευση της παραγόμενης φωτοβολταϊκής ενέργειας, εξασφαλίζοντας πιο αποτελεσματική και αξιόπιστη ενεργειακή διαχείριση.

4.2.3 Διάρθρωση Συνόλου Δεδομένων

Το περιβάλλον προσομοίωσης περιλαμβάνει επτά (7) κόμβους εκπαίδευσης που αντιστοιχούν στα επτά (7) διαφορετικά σύνολα δεδομένων. Κάθε ένα από αυτά τα σύνολα δεδομένων προέρχεται από ένα συγκεκριμένο φωτοβολταϊκό σύστημα που θα χρησιμοποιηθεί στη διαδικασία εκπαίδευσης (PV₁ – PV₇).

Το κάθε σύνολο δεδομένων χωρίζεται σε δύο (2) μέρη: το σύνολο εκπαίδευσης (training set) και το σύνολο δοκιμής (test set). Σε πειράματα που αφορούν το Federated Learning συνηθίζεται να κατανέμεται συγκεκριμένο ποσοστό δεδομένων σε κάθε ένα από αυτά τα σύνολα, π.χ. 80% για το training set και 20% για το test set. Ωστόσο, εκτός του PV₁ το οποίο επιλέχθηκε να χρησιμοποιηθεί σχεδόν ολόκληρο για εκπαίδευση του μοντέλου (με ποσοστό 99% στο σύνολο εκπαίδευσης), από τα υπόλοιπα (PV₂ – PV₇) σαν σύνολο εκπαίδευσης χρησιμοποιήθηκε διάστημα δώδεκα (12) μηνών από το κάθε σύνολο δεδομένων και τα υπόλοιπα δεδομένα αξιοποιούνται σαν σύνολο δοκιμής. Είναι προφανές ότι η περίοδος δοκιμής διαφέρει από φωτοβολταϊκό σε φωτοβολταϊκό και προκύπτει με κριτήριο τον συνολικό αριθμό των διαθέσιμων δεδομένων. Ο διαχωρισμός αυτός επιλέχθηκε προκειμένου να αποφευχθεί η παραγωγή αποτελεσμάτων που δεν αντικατοπτρίζει με ακρίβεια τα πραγματικά δεδομένα. Αυτό διασφαλίζει ότι τα αποτελέσματα της εκπαίδευσης είναι όσο το δυνατόν πιο ακριβή και αντιπροσωπευτικά της πραγματικότητας.

Με βάση τα προαναφερθέντα, τα ποσοστά που προκύπτουν για τον διαχωρισμό των δεδομένων του κάθε φωτοβολταϊκού είναι τα εξής:

PV	Training Set (%)	Test Set (%)
PV1	99	1
PV2	39,9	60,1
PV3	90,5	9,5
PV4	42,5	57,5
PV5	58,2	41,8
PV6	48,5	51,5
PV7	39,9	60,1

Πίνακας 2: Ποσοστά Διαχωρισμού Συνόλου Δεδομένων για κάθε Φωτοβολταϊκό Σύστημα

Η διαφοροποίηση των ποσοστών επιτρέπει την καλύτερη αξιοποίηση των δεδομένων και τη βελτιστοποίηση των αποτελεσμάτων της εκπαίδευσης, καθιστώντας τα πιο αξιόπιστα και χρήσιμα για μελλοντικές εφαρμογές και αναλύσεις. Με αυτόν τον τρόπο, το περιβάλλον προσομοίωσης είναι σε θέση να ανταποκριθεί καλύτερα στις προκλήσεις και τις απαιτήσεις του Federated Learning, διασφαλίζοντας την υψηλή ποιότητα των αποτελεσμάτων και την ακριβή αναπαράσταση των πραγματικών συνθηκών λειτουργίας των φωτοβολταϊκών συστημάτων.

5 Μεθοδολογία και Ανάπτυξη Αλγορίθμου

Σε αυτή την ενότητα, αρχικά παρουσιάζεται ο μαθηματικός χειρισμός της πρόβλεψης φωτοβολταϊκής ισχύος και στη συνέχεια παρουσιάζονται αναλυτικά τα χαρακτηριστικά του Federated Learning framework μαζί με τον αλγόριθμο και τον ψευδοκώδικα. Τέλος αναλύονται οι στρατηγικές Federated Learning.

5.1 Μαθηματικός Χειρισμός Δεδομένων

Η πρόβλεψη της ηλιακής ενέργειας PV (Photovoltaic) αναφέρεται στην πρακτική της πρόβλεψης της παραγωγής ηλεκτρικής ενέργειας από φωτοβολταϊκά συστήματα σε μελλοντικά χρονικά διαστήματα. Τεχνικές όπως ο αυτοπαλίνδρομος ολοκληρωμένος κινητός μέσος όρος (ARIMA), μοντέλα μη γραμμικής παλινδρόμησης, μηχανικής μάθησης (όπως νευρωνικά δίκτυα) και άλλες προσεγγίσεις μπορούν να χρησιμοποιηθούν για την πρόβλεψη της ηλιακής ενέργειας PV, ανάλογα με τις απαιτήσεις της εφαρμογής και τη διαθέσιμη πληροφορία. Μια αναλυτική μαθηματική προσέγγιση της πρόβλεψης ηλιακής ενέργειας PV, βασισμένος σε καιρικές παραμέτρους θα μπορούσε να διατυπωθεί ως εξής:

Έστω $P(t)$ η πραγματική ισχύς που παράγεται από το φωτοβολταϊκό σύστημα την χρονική στιγμή t . Η πρόβλεψη της ισχύος $\hat{P}(t)$ μπορεί να υπολογιστεί χρησιμοποιώντας ένα μοντέλο που λαμβάνει υπόψη τους διάφορους καιρικούς παράγοντες.

Συμβολισμοί:

- Ηλιακή ενέργεια (PV power): $P(t)$ είναι η παραγόμενη ηλεκτρική ισχύς από ένα φωτοβολταϊκό σύστημα στο χρόνο t .
- Πρόβλεψη ηλιακής ενέργειας (PV power forecasting): $\hat{P}(t)$ είναι η εκτιμώμενη ηλεκτρική ισχύς που προβλέπεται ότι θα παράγεται από το φωτοβολταϊκό σύστημα στο χρόνο t .
- $H(t)$: Υγρασία την χρονική στιγμή t (σε ποσοστό %).
- $T(t)$: Θερμοκρασία την χρονική στιγμή t (σε βαθμούς Κελσίου °C).
- $C(t)$: Κάλυψη από σύννεφα την χρονική στιγμή t (σε ποσοστό %).
- $W(t)$: Ταχύτητα ανέμου την χρονική στιγμή t (σε km/h).

- $S(t)$: Ηλιακή ακτινοβολία την χρονική στιγμή t (σε W/m^2).
- $D(t)$: Διασπαρτή ηλιακή ακτινοβολία την χρονική στιγμή t (σε W/m^2).
- f : Συνάρτηση που περιγράφει τη σχέση μεταξύ των καιρικών παραμέτρων και της παραγόμενης ισχύος.

Το μοντέλο πρόβλεψης της ισχύος μπορεί να εκφραστεί ως μια συνάρτηση f που λαμβάνει υπόψη αυτούς τους παράγοντες:

$$\hat{P}(t) = f(P(t), H(t), T(t), C(t), W(t), S(t), D(t))$$

Η συνάρτηση f μπορεί να είναι οποιουδήποτε είδους μαθηματικό μοντέλο, όπως νευρωνικά δίκτυα, μη γραμμική παλινδρόμηση, ή ακόμα και φυσικές προσεγγίσεις.

Στην προκειμένη περίπτωση, αφορά ένα νευρωνικό δίκτυο LSTM το οποίο θα χρησιμοποιηθεί για την βραχυπρόθεσμη πρόβλεψη (short-term) της ισχύος.

5.2 Federated Learning Framework

5.2.1 Federated Learning

Στο πλαίσιο της πρόβλεψης της ισχύος των φωτοβολταϊκών (Φ/Β), η τεχνική του Federated Learning (FL) παρουσιάζει μια καινοτόμο προσέγγιση για την αξιοποίηση δεδομένων από καταναμημένες πηγές, αντιμετωπίζοντας παράλληλα τις ανησυχίες σχετικά με το απόρρητο των δεδομένων και την επικοινωνιακή υπερφόρτωση. Το FL επιτρέπει σε πολλαπλά μέρη να εκπαιδεύουν συνεργατικά ένα μοντέλο μηχανικής μάθησης χωρίς να μοιράζονται τα ακατέργαστα δεδομένα τους. Σε αυτό το πλαίσιο, κάθε συμμετέχουσα συσκευή (ή πελάτης) διατηρεί τον έλεγχο των δεδομένων της και μοιράζεται μόνο τις ενημερώσεις του μοντέλου με έναν κεντρικό διακομιστή ή συντονιστή, ο οποίος συγκεντρώνει αυτές τις ενημερώσεις για να βελτιώσει το συνολικό μοντέλο. Πιο συνοπτικά η χρήση του Federated Learning έχει τα εξής πλεονεκτήματα:

1. Τα μοντέλα που βασίζονται στο FL μπορούν να μαθαίνουν πληροφορίες από δεδομένα σε πολλαπλές συσκευές και, συνεπώς, έχουν συνήθως μεγαλύτερη ακρίβεια από τα τοπικά μοντέλα που συνήθως χρησιμοποιούν τα ANN.

2. Τα τοπικά δεδομένα της κάθε συσκευής δεν υπάρχει η ανάγκη να μεταφορτωθούν σε κεντρικό διακομιστή, αποφεύγοντας τον κίνδυνο διαρροής προσωπικών δεδομένων και παραβίασης των σχετικών νόμων.
3. Ένας μεγάλος αριθμός συσκευών συνεργάζεται για την από κοινού εκπαίδευση ενός καθολικού μοντέλου, γεγονός που συμβάλλει στην αποτελεσματική χρήση των υπολογιστικών πόρων.

5.2.2 Μαθηματική Ανάλυση

Εξετάζοντας το Federated Learning από μια πιο μαθηματική προσέγγιση:

Έστω K ο συνολικός αριθμός των συσκευών (ή πελατών) και N ο αριθμός των παραδειγμάτων εκπαίδευσης σε κάθε συσκευή. Έστω επίσης w το μοντέλο που θέλουμε να εκπαιδεύσουμε.

Αρχικά, ο κεντρικός διακομιστής δημιουργεί ένα αρχικό μοντέλο w_0 . Κάθε συσκευή k εκπαιδεύει το μοντέλο χρησιμοποιώντας τα τοπικά της δεδομένα. Έστω w_k το μοντέλο που προκύπτει από την εκπαίδευση στη συσκευή k . Κάθε συσκευή στέλνει τις ενημερώσεις του μοντέλου $\Delta w_k = w_k - w_0$ στον κεντρικό διακομιστή.


Στη συνέχεια, ο κεντρικός διακομιστής συγκεντρώνει όλες τις ενημερώσεις από τις συσκευές και τις συνδυάζει για να ενημερώσει το γενικό μοντέλο:

$$w_{t+1} = w_t + \sum_{k=1}^K \frac{N_k}{N} \cdot \Delta w_k$$

όπου N_k είναι ο αριθμός των παραδειγμάτων εκπαίδευσης στη συσκευή k και N είναι ο συνολικός αριθμός των παραδειγμάτων εκπαίδευσης σε όλες τις συσκευές.

Με αυτόν τον τρόπο, το μοντέλο εκπαιδεύεται σε έναν κεντρικό διακομιστή χωρίς να αποκαλύπτονται τα αρχικά δεδομένα των συσκευών. Ο κεντρικός διακομιστής συγκεντρώνει τις ενημερώσεις από όλες τις συσκευές και ενημερώνει το μοντέλο ανάλογα. Έτσι, το FL παρέχει έναν τρόπο εκπαίδευσης μοντέλων μηχανικής μάθησης με μεγαλύτερη αποτελεσματικότητα και απόρρητο δεδομένων.

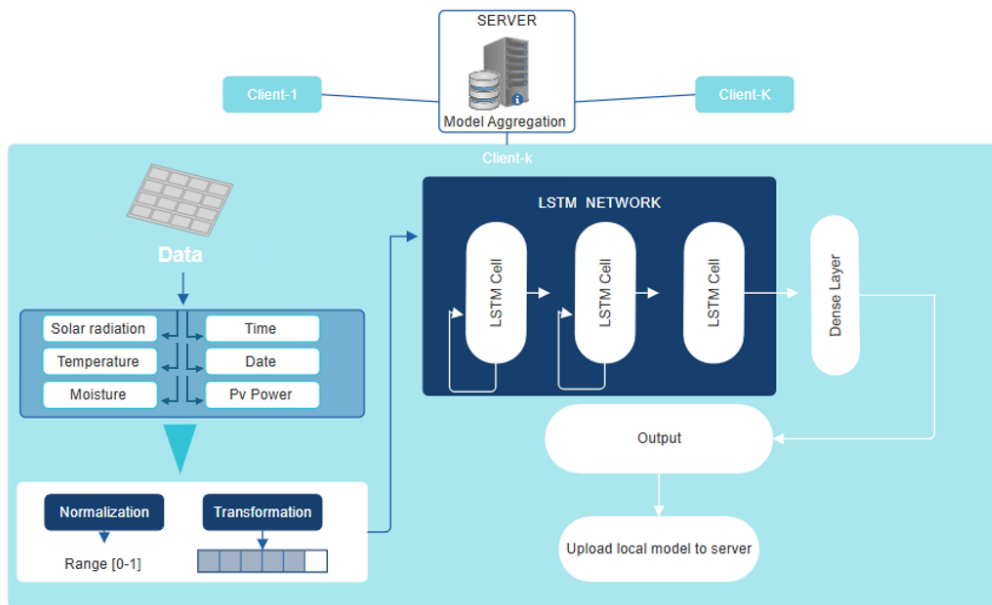
Προκειμένου, λοιπόν, να βελτιωθεί η ακρίβεια στην πρόβλεψη της φωτοβολταϊκής ισχύος μεταξύ πολλαπλών δεδομένων που φέρουν οι συνεργαζόμενες συσκευές (ή πελάτες), στην παρούσα εργασία προτείνεται ένα πλαίσιο (framework) που μέσω της τεχνικής του Federated Learning χρησιμοποιεί έξι (6) διαφορετικές στρατηγικές, την καθεμία ξεχωριστά, ώστε να εξάγει αποτελέσματα. Τα αποτελέσματα στην συνέχεια συγκρίνονται και σχολιάζονται, για να εξαχθούν συμπεράσματα για τις στρατηγικές.



Εικόνα 7: PV data aggregation method and training inside a Federated Learning Architecture [81]

5.2.3 Αναλυτική Επεξήγηση Federated Learning (FL) Framework

Ο σχεδιασμός ενός πλαισίου Federated Learning συμπεριλαμβάνει διάφορα βήματα για την υλοποίηση του. Περιλαμβάνει την προεπεξεργασία των δεδομένων, την επιλογή και την προσαρμογή της αρχιτεκτονικής του μοντέλου (LSTM), την ρύθμιση του Federated Learning καθώς και την διαδικασία εκπαίδευσης του μοντέλου ώστε να ολοκληρωθεί πλήρως η διαδικασία. Στην εικόνα 8 απεικονίζεται η αρχιτεκτονική του προτεινόμενου FL Framework για την πρόβλεψη φωτοβολταϊκής ισχύος, αποτελούμενη από αυτές τις διαδικασίες.



Εικόνα 8: Overview of the Federated Learning Framework for PV Power Forecasting

Παρακάτω επεξηγούνται αναλυτικά τα προαναφερθέντα:

1. Προεπεξεργασία δεδομένων:

Για την ανάπτυξη ενός μοντέλου Federated Learning (συγκεκριμένα με την χρήση LSTM, όπως έχει γνωστοποιηθεί παραπάνω) για την πρόβλεψη της ισχύος των φωτοβολταϊκών συστημάτων είναι απαιτούμενη η σχολαστική προεπεξεργασία των δεδομένων. Η διαδικασία αυτή περιλαμβάνει τη συλλογή ιστορικών δεδομένων που αφορούν την παραγωγή ισχύος από φωτοβολταϊκά, συμπεριλαμβανομένων μεταβλητών όπως τα επίπεδα ακτινοβολίας, η θερμοκρασία και η προηγούμενη παραγωγή ισχύος. Αφού συλλεχθούν τα δεδομένα, έπεται η μηχανική των χαρακτηριστικών. Αυτό περιλαμβάνει την εξαγωγή σημαντικών χαρακτηριστικών από τα ακατέργαστα δεδομένα, όπως η ώρα της ημέρας, η ημέρα της εβδομάδας και τα εποχιακά μοτίβα, τα οποία είναι απαραίτητα για την ακριβή πρόβλεψη. Στη συνέχεια, πραγματοποιείται κανονικοποίηση των χαρακτηριστικών εισόδου για να διασφαλιστεί ότι όλες οι μεταβλητές βρίσκονται σε παρόμοια κλίμακα, αποτρέποντας κάποιο συγκεκριμένο χαρακτηριστικό να κυριαρχήσει στη διαδικασία εκπαίδευσης του μοντέλου. Έπειτα, τα δεδομένα δομούνται σε ακολουθίες κατάλληλες για την εκπαίδευση του μοντέλου LSTM. Κάθε ακολουθία περιλαμβάνει ένα διάστημα δεδομένων μαζί με την αντίστοιχη έξοδο ισχύος-στόχου,

διευκολύνοντας τη διαδικασία εκμάθησης του μοντέλου με τη σύλληψη των χρονικών εξαρτήσεων.

2. Προσαρμογή αρχιτεκτονικής μοντέλου:

Ο σχεδιασμός και η προσαρμογή της αρχιτεκτονικής του μοντέλου LSTM είναι μια κρίσιμη πτυχή της διαδικασίας. Τα δίκτυα LSTM επιλέγονται για την ικανότητά τους να συλλαμβάνουν αποτελεσματικά τις μακροπρόθεσμες εξαρτήσεις σε διαδοχικά δεδομένα, γεγονός που τα καθιστά ιδανικά για εργασίες πρόβλεψης χρονοσειρών. Η αρχιτεκτονική του μοντέλου αποτελείται από στρώματα LSTM ακολουθούμενα από ένα πυκνό στρώμα εξόδου για πρόβλεψη. Το σχήμα εισόδου του μοντέλου LSTM καθορίστηκε με βάση το μήκος της ακολουθίας των δεδομένων και τον αριθμό των χαρακτηριστικών τους. Οι υπερπαραμέτροι, συμπεριλαμβανομένου του αριθμού των μονάδων LSTM, του ρυθμού μάθησης, του ρυθμού εγκατάλειψης και της επιλογής του βελτιστοποιητή, ρυθμίστηκαν λεπτομερώς μέσω πειραματισμού για τη βελτιστοποίηση της απόδοσης του μοντέλου. Επιπλέον, λήφθηκαν υπόψη τεχνικές κανονικοποίησης για την αποφυγή της υπερπροσαρμογής και την ενίσχυση της γενίκευσης.

3. Εφαρμογή Federated Learning:

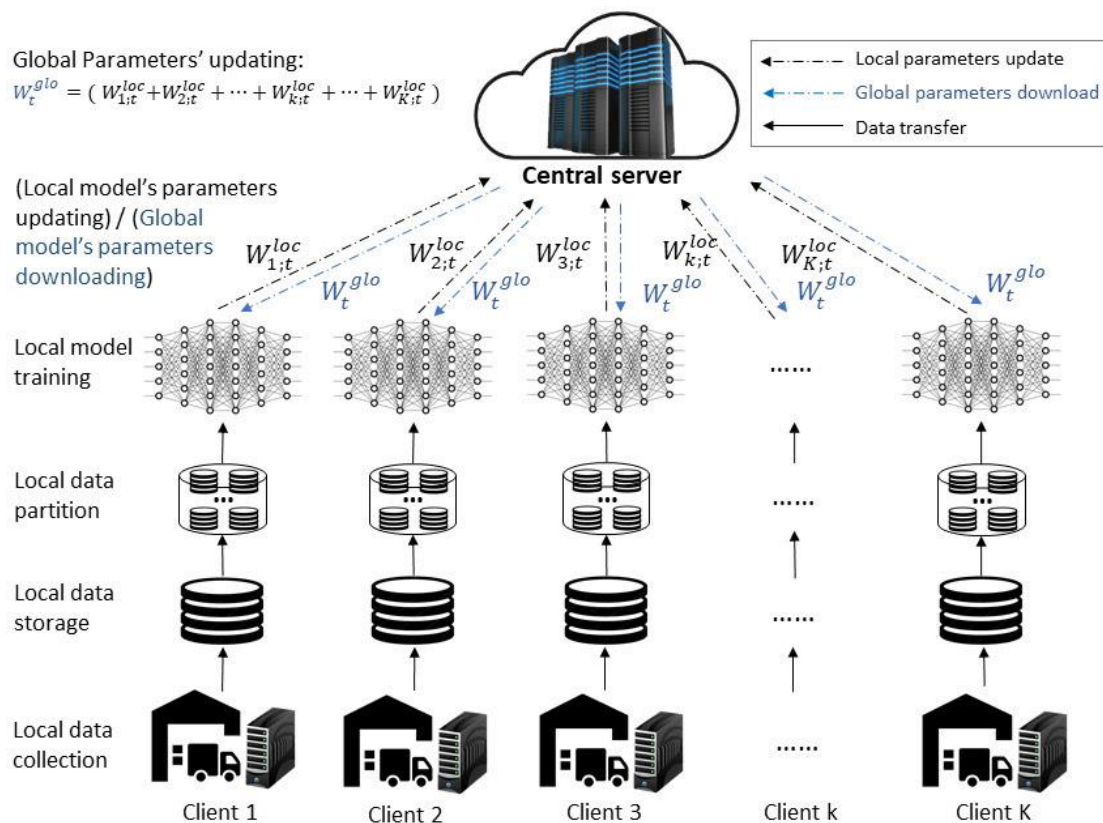
Η εφαρμογή του FL απαιτεί τη δημιουργία μιας αρχιτεκτονικής πελάτη-εξυπηρετητή, όπου πολλαπλοί πελάτες, που αντιπροσωπεύουν φωτοβολταϊκά συστήματα, διατηρούν τα αντίστοιχα δεδομένα τους τοπικά. Ένας κεντρικός διακομιστής συντονίζει τη διαδικασία εκπαίδευσης του μοντέλου, διασφαλίζοντας παράλληλα το απόρρητο και την ασφάλεια των δεδομένων. Η κατάτμηση των δεδομένων πραγματοποιείται για να διανεμηθούν τα δεδομένα στους πελάτες, διατηρώντας παράλληλα επαρκείς πληροφορίες για την ουσιαστική εκπαίδευση του μοντέλου. Δημιουργείται ένα πρωτόκολλο επικοινωνίας που επιτρέπει την ασφαλή ανταλλαγή ενημερώσεων μοντέλων μεταξύ των πελατών και του διακομιστή, χρησιμοποιώντας τεχνικές όπως το federated averaging για την γενίκευση των αποτελεσμάτων.

4. Διαδικασία εκπαίδευσης μοντέλου:

Η διαδικασία εκπαίδευσης του μοντέλου μάθησης LSTM με FL περιλαμβάνει διάφορα επαναληπτικά βήματα. Η αρχικοποίηση των παραμέτρων του μοντέλου πραγματοποιείται τυχαία επιλέγοντας έναν πελάτη. Διεξάγονται πολλαπλοί γύροι FL, όπου οι πελάτες εκπαιδεύουν τα τοπικά τους μοντέλα στα αντίστοιχα δεδομένα τους και διαβιβάζουν τις

ενημερώσεις του μοντέλου στον κεντρικό διακομιστή. Ο διακομιστής συγκεντρώνει αυτές τις ενημερώσεις χρησιμοποιώντας τεχνικές (στρατηγικές), που αναλύονται αργότερα στην εργασία, για την ενημέρωση των συνολικών παραμέτρων του μοντέλου. Για την παρακολούθηση της σύγκλισης και την αποφυγή της υπερπροσαρμογής διενεργείται περιοδική αξιολόγηση της απόδοσης του συνολικού μοντέλου σε ένα σύνολο επικύρωσης. Η διαδικασία εκπαίδευσης συνεχίζεται έως ότου ικανοποιηθεί ένα προκαθορισμένο κριτήριο διακοπής, και δηλαδή η επίτευξη ενός μέγιστου αριθμού γύρων εκπαίδευσης.

Αφού ολοκληρωθεί η διαδικασία εκπαίδευσης του μοντέλου και γενικότερα οι παραπάνω ενέργειες, ακολουθεί η αξιολόγηση του μοντέλου που δημιουργήθηκε, προκειμένου να είναι εφικτή η μετέπειτα χρήση του σε πραγματικές εφαρμογές. Μετρικές όπως το μέσο απόλυτο σφάλμα (MAE), η ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) και ο συντελεστής προσδιορισμού (R-τετράγωνο) χρησιμοποιούνται για την αξιολόγηση της απόδοσης του μοντέλου σε ένα σύνολο δοκιμαστικών δεδομένων. Το μοντέλο εξετάζεται στην πρόβλεψη της παραγωγής ενέργειας από φωτοβολταϊκά σε διαφορετικές συνθήκες και σενάρια ώστε να παραμείνει αποτελεσματικό και ακριβές σε όποια εφαρμογή κληθεί να εφαρμοστεί.



Εικόνα 9: Illustration of the process of a Federated Learning framework [82]

5.2.4 Προβλήματα

Πολλά είναι τα προβλήματα που μπορεί να προκύψουν με την ενσωμάτωση ενός Federated Learning πλαισίου σε ένα μοντέλο LSTM.

Ένα από τα σημαντικότερα είναι η ετερογένεια των δεδομένων. Τα φωτοβολταϊκά συστήματα μπορεί να διαφέρουν σημαντικά ως προς τη θέση, τον προσανατολισμό, το μέγεθος και άλλους παράγοντες. Αυτή η ετερογένεια μπορεί να οδηγήσει σε προκλήσεις κατά την εκπαίδευση ενός μοντέλου που να αποδίδει καλά σε όλες τις συσκευές. Η διασφάλιση ότι ο αλγόριθμος μπορεί να χειριστεί αποτελεσματικά αυτή την ποικιλομορφία είναι ζωτικής σημασίας. Γι' αυτό άλλωστε στην Ανάφ. [70] ακολουθείται μια τεχνική προσωποποίησης κάνοντας διάκριση μεταξύ προσωπικών και κοινών για όλους στρωμάτων για κάθε φωτοβολταϊκό.

Εξίσου σημαντικό θέμα αποτελεί και η επιβάρυνση στην επικοινωνία μεταξύ του κεντρικού διακομιστή και των φωτοβολταϊκών (πελατών). Κατά την διάρκεια της διαδικασίας εκπαίδευσης, η τεχνική του FL απαιτεί αλληλεπίδραση των συμμετεχόντων στην διαδικασία. Αυτή η επιβάρυνση επικοινωνίας μπορεί να είναι σημαντική, ειδικά αν οι συσκευές (φωτοβολταϊκά) έχουν περιορισμένο εύρος

ζώνης ή αναξιόπιστες συνδέσεις. Η ελαχιστοποίηση της επιβάρυνσης επικοινωνίας με παράλληλη διατήρηση της ακρίβειας του μοντέλου αποτελεί βασική πρόκληση όπως αναλύεται εκτενώς και στην Αναφ. [71]. Εκεί προτάθηκε και σχεδιάστηκε ένα πλαίσιο το οποίο με πιθανοτικό τρόπο διαλέγει για μετάδοση τις συσκευές οι οποίες είναι πιο πιθανό να βελτιώσουν σημαντικά την ταχύτητα σύγκλισης και να συμβάλλουν στην μείωση των απωλειών εκπαίδευσης.

Συχνό πρόβλημα αποτελεί όμως και η παροδική μείωση απόδοσης του μοντέλου. Τα χαρακτηριστικά των φωτοβολταϊκών συστημάτων μπορούν να αλλάξουν με την πάροδο του χρόνου λόγω παραγόντων όπως η γήρανση, οι περιβαλλοντικές συνθήκες και οι δραστηριότητες συντήρησης. Η αλλαγή αυτή των χαρακτηριστικών μπορεί να είναι η αιτία ώστε το μοντέλο να αποκλίνει σημαντικά από τις έως τώρα αποδόσεις του στην πρόβλεψη καθώς δεν θα είναι ενημερωμένο κατάλληλα. Η τακτική επανεκπαίδευση του μοντέλου και η προσαρμογή στις μεταβαλλόμενες συνθήκες είναι απαραίτητες για τον μετριασμό αυτού του προβλήματος. Το συγκεκριμένο ζήτημα συζητούν και οι συγγραφείς της Αναφ. [72], όπου αποδεικνύουν ότι είναι εφικτό να εκπαιδευτεί ένα μοντέλο αποτελεσματικά σε εργασίες στις οποίες δεν είναι εξοικειωμένο για μεγάλο χρονικό διάστημα. Πετυχαίνουν την καινοτομία αυτή, ακολουθώντας μια προσέγγιση η οποία κρατά στην μνήμη τις παλιές εργασίες επιβραδύνοντας επιλεκτικά τη μάθηση στα βάρη που είναι σημαντικά για αυτές.

Η επιλογή των δεικτών μάθησης είναι σημαντική όμως και για τον μετριασμό της μεροληψίας υπέρ κάποιου φωτοβολταϊκού. Το Federated Learning βασίζεται στην υπόθεση ότι η κατανομή των δεδομένων στα φωτοβολταϊκά είναι αντιπροσωπευτική του συνολικού πληθυσμού. Ωστόσο, οι προκαταλήψεις στα δεδομένα, όπως η υποεκπροσώπηση ορισμένων στοιχείων, μπορεί να οδηγήσουν σε μεροληπτικά μοντέλα. Η διασφάλιση της δικαιοσύνης και ο μετριασμός της μεροληψίας στα μοντέλα ομοσπονδιακής μάθησης αποτελεί σημαντικό ζήτημα κάτι που είναι εμφανές και από το έργο στην Αναφ. [73], όπου το συγκεκριμένο πρόβλημα αναλύεται εκτενώς από τους συγγραφείς και δημιουργούν ένα FL framework που βελτιστοποιεί τόσο την ακρίβεια όσο και τη δικαιοσύνη του μοντέλου επιλύοντας το πρόβλημα της μεροληψίας.

Τέλος, ένα καίριο ζητούμενο στον τομέα του FL είναι η επεκτασιμότητα του πλαισίου. Καθώς αυξάνεται ο αριθμός των συμμετεχόντων φωτοβολταϊκών, η επεκτασιμότητα του πλαισίου FL καθίσταται ζωτικής σημασίας. Η διασφάλιση ότι το σύστημα μπορεί να χειριστεί αποτελεσματικά έναν μεγάλο αριθμό φωτοβολταϊκών, διατηρώντας παράλληλα τις επιδόσεις, αποτελεί σημαντική πρόκληση. Αυτός είναι και ο στόχος, σε μία πιο γενική μορφή, στην Αναφ. [74],

όπου σχεδιάστηκε ένα σύστημα FL με δυνατότητα επεκτασιμότητας στον τομέα των κινητών συσκευών.

Λαμβάνοντας υπ' όψη όλα τα παραπάνω προβλήματα αλλά και τις λύσεις τις οποίες έχουν προταθεί από ερευνητές που ασχολήθηκαν με τους αντίστοιχους τομείς, στην παρούσα εργασία υλοποιήθηκε ένα Federated Learning framework το οποίο καλύπτει εν μέρη ένα μεγάλο μέρος των προαναφερθέντων ζητημάτων. Πιο συγκεκριμένα, χρησιμοποιώντας μεγάλο όγκο δεδομένων εκπαίδευσης, επιλέγοντας φωτοβολταϊκά με διαφορετικά χαρακτηριστικά, μειώνοντας και περιορίζοντας όσο το δυνατόν περισσότερο την επικοινωνία μεταξύ διακομιστή και φωτοβολταϊκών αλλά και ρυθμίζοντας τους δείκτες μάθησης από κάθε φωτοβολταϊκό, έγινε προσπάθεια να μετριαστούν τα προβλήματα της ετερογένειας των δεδομένων, της επιβάρυνσης στην επικοινωνία, καθώς και της μεροληψίας και της επεκτασιμότητας του πλαισίου. Στόχος είναι να διατηρηθεί η απόδοση, ανεξαρτήτως της επίδρασης τυχόν προβλημάτων.

5.2.5 Αλγόριθμος

Το Federated Learning αντιπροσωπεύει μια πρωτοποριακή αλλαγή στη μηχανική μάθηση, επιτρέποντας τη συνεργασία για την εκπαίδευση μοντέλων σε αποκεντρωμένες συσκευές, προστατεύοντας παράλληλα το απόρρητο των δεδομένων. Για την δημιουργία όμως, ενός αποδοτικού αλγόριθμου που θα έχει την παραπάνω συνεισφορά είναι απαραίτητο να γίνει ανάλυση των βασικών βημάτων και διαδικασιών που θα συμμετέχουν σε αυτόν. Με την διάσπαση της διαδικασίας σε διακριτά βήματα, το πλαίσιο που παρουσιάζεται παρακάτω προσφέρει μια δομημένη προσέγγιση για την αξιοποίηση της συλλογικής ευφυΐας των κατανεμημένων συσκευών για την εκπαίδευση μοντέλων. Περιλαμβάνει τις φάσεις αρχικοποίησης, client setup, ορισμού της αρχιτεκτονικής του μοντέλου, εκπαίδευσης, συνάθροισης, αξιολόγησης, επανάληψης και τερματισμού.

Ολοκληρωμένο πλαίσιο αλγορίθμου για Federated Learning:

1. Αρχικοποίηση:

- Έναρξη του federated learning server.
- Ορισμός του αριθμού των clients.
- Καθορισμός της στρατηγικής FL που θα ακολουθήσει ο server (π.χ. FedAvg, FedProx).
- Καθορισμός των υπολογιστικών πόρων (π.χ. CPU, GPU).

2. Client Setup:

- Ορισμός συνάρτησης για την δημιουργία clients.
- Εντός της συνάρτησης:
 - Φόρτωση δεδομένων που αφορούν τον client από το σύνολο δεδομένων.
 - Προεπεξεργασία των δεδομένων ανάλογα με τις ανάγκες του συστήματος (π.χ. κανονικοποίηση, επιλογή χαρακτηριστικών).
 - Δημιουργία ενός τοπικού μοντέλου (π.χ. νευρωνικό δίκτυο) στον client.
 - Προετοιμασία των φορέων των δεδομένων για εκπαίδευση και επικύρωση.

3. Ορισμός αρχιτεκτονικής του μοντέλου:

- Καθορισμός της αρχιτεκτονικής του μοντέλου του νευρωνικού δικτύου (π.χ. LSTM).
- Προσδιορισμός του μεγέθους εισόδου, του κρυφού μεγέθους, του αριθμού των επιπέδων και των υπολοίπων παραμέτρων του δικτύου.

4. Training:

- Εφαρμογή συναρτήσεων για την εκπαίδευση του μοντέλου τοπικά σε κάθε client:
 - Λήψη των global παραμέτρων από τον διακομιστή.
 - Ενημέρωση του τοπικού μοντέλου χρησιμοποιώντας τα δεδομένα του client.
 - Εκπαίδευση του τοπικού μοντέλου για έναν καθορισμένο αριθμό εποχών.
 - Υπολογισμός των απωλειών και των μετρικών επίδοσης (π.χ. ακρίβεια, RMSE) στο σύνολο δεδομένων επικύρωσης.

- Επιστροφή των ενημερωμένων παραμέτρων και μετρήσεων του μοντέλου στο διακομιστή.

5. Συνάθροιση:

- Καθορισμός μεθόδων για τη συγκέντρωση και την συνάθροιση των ενημερώσεων μοντέλου από τους clients στο διακομιστή.
- Συνάθροιση των ενημερώσεων με χρήση federated averaging ή άλλων τεχνικών.
- Αξιολόγηση μοντέλου και καταγραφή στον κεντρικό διακομιστή (προαιρετικά).

6. Αξιολόγηση:

- Εφαρμογή συναρτήσεων για την αξιολόγηση του συνολικού μοντέλου:
 - Αποστολή των συνολικών παραμέτρων του μοντέλου σε κάθε client για αξιολόγηση.
 - Υπολογισμός επιδόσεων σε τοπικά δεδομένα σε κάθε client.
 - Συγκέντρωση και ανάλυση των αποτελεσμάτων αξιολόγησης για την αποτίμηση της απόδοσης του μοντέλου.

7. Επανάληψη:

- Επανάληψη των βημάτων 4-6 για πολλαπλούς γύρους ή εποχές federated learning.
- Παρακολούθηση της σύγκλισης του συνολικού μοντέλου κατά τη διάρκεια των επαναλήψεων.
- Προαιρετικά, προσαρμογή των υπερπαραμέτρων ή των στρατηγικών με βάση τις μετρήσεις επίδοσης.

8. Τερματισμός:

- Καθορισμός κριτηρίων διακοπής για τον τερματισμό της διαδικασίας federated learning (π.χ. όριο σύγκλισης, μέγιστος αριθμός γύρων).
- Διακοπή της εκπαίδευσης όταν πληρούνται τα κριτήρια ή όταν συμπληρωθεί ο μέγιστος αριθμός γύρων.

Συνοψίζοντας, το περιγραφόμενο πλαίσιο Federated Learning παρέχει μια ισχυρή δομή για την υλοποίηση καταναμημένων αλγορίθμων μηχανικής μάθησης, συμπεριλαμβανομένων εκείνων που είναι προσαρμοσμένοι για συγκεκριμένες εφαρμογές, όπως η πρόβλεψη της ισχύος των φωτοβολταϊκών (ΦΒ). Με την αξιοποίηση του FL, ιδίως στο πλαίσιο της πρόβλεψης ισχύος φωτοβολταϊκών συστημάτων, μπορούμε να αντιμετωπίσουμε τις προκλήσεις που σχετίζονται με το απόρρητο των δεδομένων, την επεκτασιμότητα και την ποικιλομορφία σε καταναμημένα σύνολα δεδομένων.

Στη συγκεκριμένη περίπτωση της πρόβλεψης ισχύος φωτοβολταϊκών συστημάτων, ο αλγόριθμος επεκτείνει τη χρησιμότητά του, επιτρέποντας την τοπική εκπαίδευση σε δεδομένα που παράγονται από διάφορες γεωγραφικές τοποθεσίες, καιρικές συνθήκες και περιβαλλοντικές συνθήκες.

5.2.6 Ψευδοκώδικας αλγορίθμου Federated Learning

Εφαρμόζοντας λοιπόν τα παραπάνω βήματα είναι εφικτό να δημιουργηθεί ο παρακάτω ψευδοκώδικας που δίνει μια πιο σαφή προσέγγιση στην ακριβή υλοποίηση του Federated Learning framework με χρήση κώδικα.

Για την έναρξη της διαδικασίας εκπαίδευσης του μοντέλου είναι απαραίτητη η αρχικοποίηση ορισμένων στοιχείων. Το ακόλουθο τμήμα ψευδοκώδικα, λοιπόν, αφορά την αρχικοποίηση του συστήματος.

```
// Initialization
initialize FederatedLearningServer
num_clients = defineNumberOfClients()
num_epochs = defineNumberOfEpochs()
server_Strategy = specifyServerStrategy()
```

Εικόνα 10: Pseudocode of the Initialization of the Federated Learning process

Στη φάση της αρχικοποίησης της διαδικασίας του Federated Learning, καθορίζονται κάποια βασικά στοιχεία. Αρχικοποιείται ένας `FederatedLearningServer`, ο οποίος αποτελεί τον κεντρικό κόμβο που διαχειρίζεται το συνολικό συντονισμό της διαδικασίας εκπαίδευσης και εκμάθησης σε πολλαπλούς clients. Ο αριθμός των clients που συμμετέχουν στη διαδικασία εκμάθησης ορίζεται από το `num_clients` και βασίζεται στον αριθμό των φωτοβολταϊκών που είναι επιθυμητό να χρησιμοποιηθούν για εκπαίδευση. Ορίζεται επίσης, ο αριθμός των εποχών (Μια εποχή είναι ένα πλήρες πέρασμα σε

ολόκληρο το σύνολο δεδομένων εκπαίδευσης) ή αλλιώς επαναλήψεων εκπαίδευσης από την μεταβλητή `num_epochs`. Τέλος καθορίζεται η στρατηγική για τον διακομιστή η οποία συμβολίζεται ως `server_Strategy`. Η στρατηγική περιλαμβάνει τον αλγόριθμο για την διαδικασία συγκέντρωσης των ενημερώσεων του μοντέλου από τους clients και γενικότερα τις μεθόδους που χρησιμοποιεί ο κεντρικός διακομιστής προκειμένου να συντονίσει την συνολική διαδικασία μάθησης.

Η διαδικασία συνεχίζεται με την ρύθμιση των παραμέτρων για την εκκίνηση των clients. Το παρακάτω κομμάτι ψευδοκώδικα δείχνει τον τρόπο επίτευξης μιας τέτοιας ενέργειας.

```
// Client Setup
function createClient():
for each round do
    for each client in parallel do
        client_Data = loadClientDataFromDataset()
        preprocessed_Data = preprocessData(clientData)
        local_lstm_model = InitializeLocalLSTMModel()
        prepare_Data_Loaders(localModel, preprocessedData)
```

Εικόνα 11: Pseudocode of the Client Setup of the Federated Learning process

Η συνάρτηση `createClient()`, δημιουργεί τους clients και είναι υπεύθυνη για την αρχικοποίηση των clients που συμμετέχουν στη διαδικασία του Federated Learning. Κατά τη διάρκεια κάθε γύρου εκπαίδευσης, η συνάρτηση λειτουργεί παράλληλα για κάθε client. Για κάθε γύρο εκπαίδευσης, η συνάρτηση φορτώνει για κάθε client, τα δικά του δεδομένα από ένα σύνολο δεδομένων (`client_Data`) χρησιμοποιώντας την `loadClientDataFromDataset()`. Τα δεδομένα αφορούν τα ιστορικά δεδομένα που περιγράφουν τις καιρικές συνθήκες (π.χ. Υγρασία, Θερμοκρασία, Ηλιακή ακτινοβολία) καθώς και τα έως τώρα δεδομένα παραγωγής ισχύος. Τα δεδομένα υποβάλλονται σε προεπεξεργασία προκειμένου να είναι δυνατό να χρησιμοποιηθούν στην εκπαίδευση. Η προεπεξεργασία περιλαμβάνει την περισυλλογή μόνο των χρήσιμων πληροφοριών από το σύνολο των δεδομένων, την κανονικοποίηση των δεδομένων και την κατάλληλη διαμόρφωση τους ώστε να χρησιμοποιηθούν από το μοντέλο LSTM. Στη συνέχεια, κάθε client αρχικοποιεί το δικό του τοπικό μοντέλο LSTM (`local_lstm_model`) χρησιμοποιώντας την `InitializeLocalLSTMModel()`. Οι φορτωτές των δεδομένων προετοιμάζονται για αυτά τα τοπικά μοντέλα διαμερίζοντας τα σε παρτίδες, ώστε να χειρίζονται αποτελεσματικά τα δεδομένα κατά τη διάρκεια της διαδικασίας εκπαίδευσης.

Χρησιμοποιείτε η `prepare_Data_Loaders(localModel, preprocessedData)` για να επιτευχθεί αυτό. Αυτή η ρύθμιση διασφαλίζει ότι κάθε client είναι έτοιμος με το τοπικό του μοντέλο και τα προεπεξεργασμένα δεδομένα του για να συμμετάσχει στους γύρους του Federated Learning.

Αφού ρυθμιστούν οι παράμετροι των clients είναι απαραίτητο να αρχικοποιηθεί και το μοντέλο LSTM, όπως είναι εμφανές και στο ακόλουθο τμήμα ψευδοκώδικα.

```
// Model Architecture : Initialize global LSTM model with random parameters or pre-trained weights
global_lstm_model = LSTMModel()
return global_lstm_model
```

Εικόνα 12: Pseudocode of the Model Architecture Setup of the Federated Learning process

Σε αυτό το μέρος του ψευδοκώδικα, αρχικοποιείται ένα συνολικό μοντέλο LSTM (`global_lstm_model`) το οποίο εκκινεί με τυχαίες παραμέτρους, καθώς δεν υπάρχουν ακόμη προεκπαιδευμένα βάρη. Αυτό το μοντέλο λειτουργεί ως το κεντρικό μοντέλο που οι clients στοχεύουν να εκπαιδεύσουν συνεργατικά. Οι παράμετροι του μοιράζονται σε όλους τους clients και ενημερώνονται επαναληπτικά καθώς το μοντέλο συγκεντρώνει ενημερώσεις από τα τοπικά μοντέλα που εκπαιδεύονται στα δεδομένα των μεμονωμένων clients.

Εφόσον, έχουν ολοκληρωθεί όλες οι διαδικασίες αρχικοποίησης των διαφόρων τμημάτων που συνθέτουν το βασικό κορμό της υλοποίησης, σειρά έχει η έναρξη της εκπαίδευσης του μοντέλου. Ο ψευδοκώδικας που απεικονίζει αυτή την ενέργεια είναι ο ακόλουθος:

```

// Training
function trainLocalModel(client, globalModel):
    for each local epoch do
        for each batch in preprocessed_data do
            inputs, targets = batch
            // Forward pass
            outputs = local_lstm_model(inputs)
            // Calculate loss
            loss = CalculateLoss(outputs, targets)
            // Backward pass
            Backpropagate(loss)
            // Update parameters using gradient descent
            UpdateParameters()
        end for
    end for
    return local_lstm_model.get_parameters()

```

Εικόνα 13: Pseudocode of the Training procedure of the Federated Learning process

Η συνάρτηση `trainLocalModel(client, globalModel)` περιγράφει τη διαδικασία εκπαίδευσης για το τοπικό μοντέλο κάθε client. Για κάθε τοπική επανάληψη, η συνάρτηση επεξεργάζεται παρτίδες προεπεξεργασμένων δεδομένων. Μέσα σε κάθε δέσμη, οι είσοδοι και οι στόχοι διαχωρίζονται και διεξάγεται ένα forward pass (εμπρόσθιο πέρασμα) για τη δημιουργία εξόδων από το τοπικό μοντέλο LSTM. Στη συνέχεια υπολογίζεται η απώλεια μεταξύ των εξόδων και των στόχων. Ακολουθεί ένα backpropagate (προς τα πίσω πέρασμα), το οποίο υπολογίζει τις κλίσεις και οι παράμετροι του μοντέλου ενημερώνονται με τη χρήση της καθόδου κλίσης (gradient descent). Τέλος η συνάρτηση επιστρέφει τις παραμέτρους του τοπικού μοντέλου. Η διαδικασία που υλοποιεί η συνάρτηση επιτρέπει σε κάθε πελάτη να μαθαίνει από τα δεδομένα του πριν μοιραστεί τις ενημερώσεις του μοντέλου με τον κεντρικό διακομιστή.

Με το πέρας της εκπαίδευσης των τοπικών μοντέλων και προκειμένου να λειτουργήσει ορθά η τεχνική του Federated Learning είναι επιτακτική η συνάθροιση των βαρών από τα εκπαιδευμένα μοντέλα. Η διεργασία που πρέπει να πραγματοποιηθεί είναι αρκετά απλή και παρουσιάζεται με το ακόλουθο κομμάτι ψευδοκώδικα.

```
// Aggregation
function aggregateModelUpdates(modelUpdates):
    aggregated_Model = federatedAveraging(modelUpdates)
    return aggregatedModel
```

Εικόνα 14: Pseudocode of the Aggregation procedure of the Federated Learning process

Η φάση συνάθροισης περιλαμβάνει τη συνάρτηση `aggregateModelUpdates(modelUpdates)`, όπου συνδυάζονται οι ενημερώσεις από τα τοπικά μοντέλα όλων των clients. Το συγκεντρωτικό μοντέλο αντιπροσωπεύει τη συνδυασμένη γνώση από όλους τους συμμετέχοντες, ενισχύοντας έτσι την ικανότητα γενίκευσης του παγκόσμιου μοντέλου σε διαφορετικές κατανομές δεδομένων.

Έχοντας ολοκληρώσει τα παραπάνω βήματα η διαδικασία προχωρά στην αξιολόγηση του μοντέλου. Ο ψευδοκώδικας που ακολουθεί παρουσιάζει τον τρόπο επίτευξης της.

```
// Evaluation
function evaluateGlobalModel(globalModel):
    evaluation_Results = []
    for each client in clients:
        evaluation_Result = evaluateModelLocally(globalModel, clientTestData)
        evaluation_Results.append(evaluationResult)
    aggregated_Results = aggregateEvaluationResults(evaluationResults)
    return aggregated_Results
```

Εικόνα 15: Pseudocode of the Evaluation procedure of the Federated Learning process

Η συνάρτηση `evaluateGlobalModel(globalModel)` είναι υπεύθυνη για την αξιολόγηση της απόδοσης του συγκεντρωτικού συνολικού μοντέλου. Το μοντέλο αξιολογείται συλλέγοντας τα αποτελέσματα αξιολόγησης από την εκτέλεση του συνολικού μοντέλου στα τοπικά δεδομένα δοκιμών του κάθε πελάτη με τη χρήση της `evaluateModelLocally(globalModel, clientTestData)`. Η συλλογή γίνεται στον πίνακα `evaluation_Results` και στη συνέχεια τα αποτελέσματα αθροίζονται για να παρέχουν μια ολοκληρωμένη μετρική απόδοσης για το παγκόσμιο μοντέλο. Αυτό το βήμα αξιολόγησης είναι απαραίτητο για τη μέτρηση της αποτελεσματικότητας και της ακρίβειας του συνολικού μοντέλου μετά από κάθε γύρο εκπαίδευσης.

Προκειμένου να εξαχθούν αποτελέσματα ένας μόνο γύρος επανάληψης δεν είναι αρκετός, καθώς με μία και μόνο επανάληψη δεν είναι εφικτό να ληφθεί απόφαση

για την αποτελεσματικότητα του μοντέλου. Το ακόλουθο τμήμα ψευδοκώδικα δείχνει αυτή την διεργασία.

```
// Iteration
for each round in num_epochs:
    for each client in clients:
        global_Model_Params = FederatedLearningServer.globalModelParams
        local_Model_Params, validation_Metrics = trainLocalModel(client, globalModelParams)
        FederatedLearningServer.updateGlobalModel(localModelParams, validationMetrics)
    aggregated_Model = aggregateModelUpdates(FederatedLearningServer.modelUpdates)
    FederatedLearningServer.updateGlobalModel(aggregated_Model)
    aggregated_Results = evaluateGlobalModel(FederatedLearningServer.globalModel)
```

Εικόνα 16: Pseudocode of the Iteration procedure of the Federated Learning process

Αυτό το μέρος του ψευδοκώδικα αναπαριστά την επαναληπτική διαδικασία εκπαίδευσης και ενημέρωσης του συνολικού μοντέλου βασισμένο στην μεταβλητή `num_epochs`. Κατά τη διάρκεια κάθε γύρου, οι παγκόσμιες παράμετροι του μοντέλου διανέμονται σε όλους τους clients. Κάθε client εκπαιδεύει το τοπικό του μοντέλο χρησιμοποιώντας αυτές τις παραμέτρους και επιστρέφει ενημερωμένες παραμέτρους μαζί με μετρικές επικύρωσης. Αυτές οι ενημερώσεις αποστέλλονται πίσω στο διακομιστή, όπου και συγκεντρώνονται. Έπειτα, ο διακομιστής ενημερώνει το παγκόσμιο μοντέλο με τις συγκεντρωτικές παραμέτρους. Μετά την ενημέρωση του μοντέλου, αυτό αξιολογείται για να διασφαλιστεί ότι η απόδοσή του βελτιώνεται με την πάροδο του χρόνου. Αυτή η επαναληπτική διαδικασία επιτρέπει στο μοντέλο να μαθαίνει προοδευτικά και να βελτιώνεται με κάθε εποχή.

Τέλος, η διαδικασία εκπαίδευσης περιλαμβάνει μια φάση τερματισμού όπως αυτή φαίνεται στον ψευδοκώδικα.

```
// Termination
if stoppingCriteriaMet():
    stopTraining()
```

Εικόνα 17: Pseudocode of the Termination of the Federated Learning process

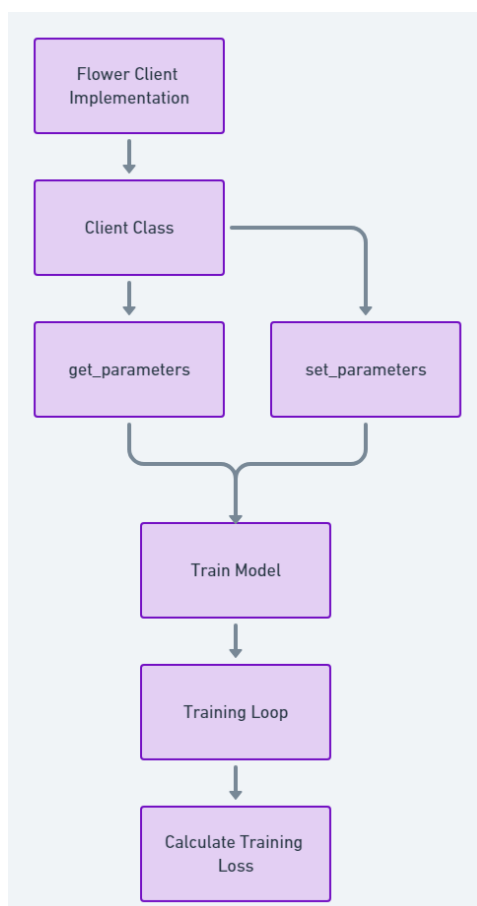
Εάν πληρούνται ορισμένα κριτήρια τερματισμού, και συγκεκριμένα η επίτευξη του προκαθορισμένου αριθμού εποχών, η διαδικασία εκπαίδευσης διακόπτεται. Με τον τρόπο αυτό διασφαλίζεται ότι η εκπαίδευση δεν συνεχίζεται επ' αόριστον και

σταματά μόλις το μοντέλο επιτύχει τους επιθυμητούς στόχους απόδοσης. Η φάση αυτή εξασφαλίζει την αποτελεσματική χρήση των υπολογιστικών πόρων και την έγκαιρη ολοκλήρωση της διαδικασίας του Federated Learning.

5.2.7 Διαγράμματα Ροής

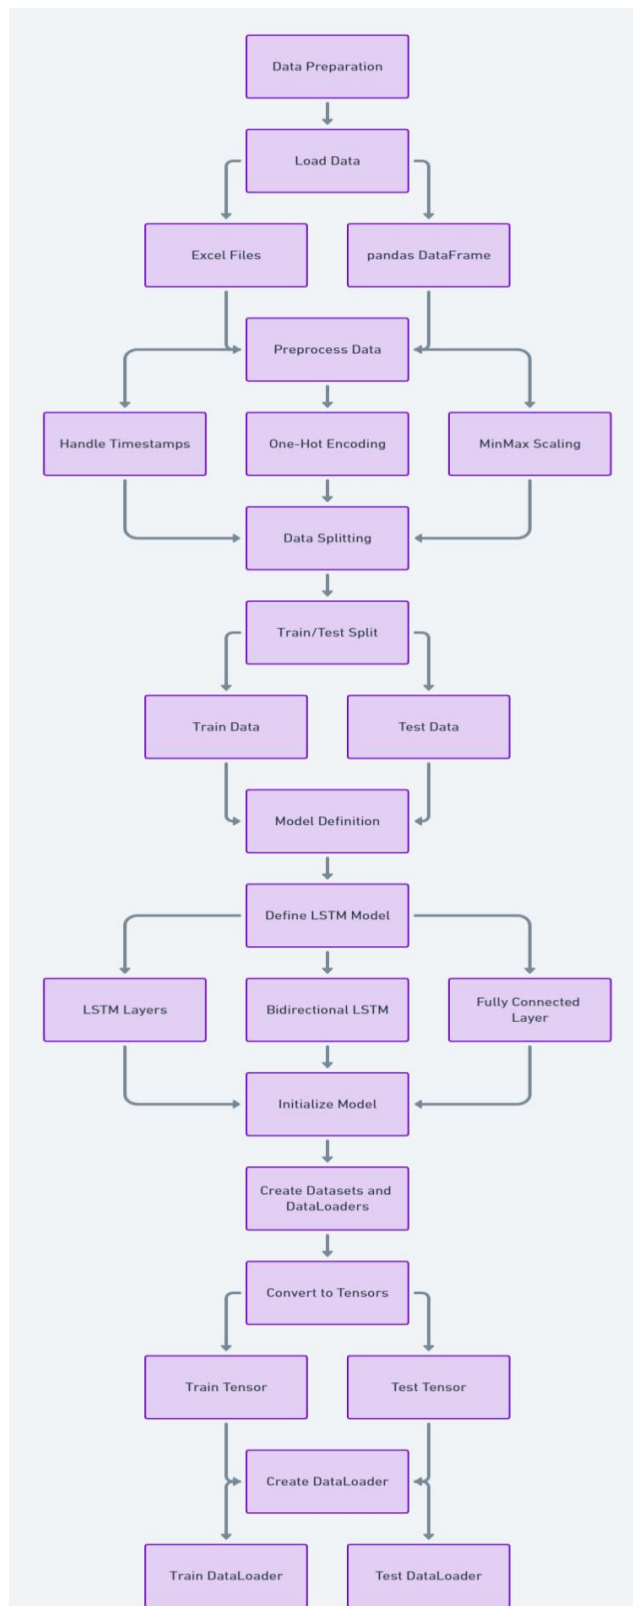
Κάθε φορά που επιλέγεται να τρέξει το πρόγραμμα και να γίνει εκ νέου εκπαίδευση των μοντέλων, εκτελούνται οι ενέργειες που περιεγράφηκαν αναλυτικά με τον ψευδοκώδικα. Είναι σειρά ενεργειών που υλοποιούνται για να εξασφαλίσουν την ορθή εισαγωγή και εκπαίδευση των δεδομένων, την αρχικοποίηση των clients καθώς και συνολικά την αποδοτικότερη λειτουργία και αξιολόγηση του προγράμματος.

Τα διαγράμματα ροής αυτής της διαδικασίας, δημιουργήθηκαν με την βοήθεια της εφαρμογής Whimsical [75] και παρουσιάζονται παρακάτω (σε 3 κομμάτια).



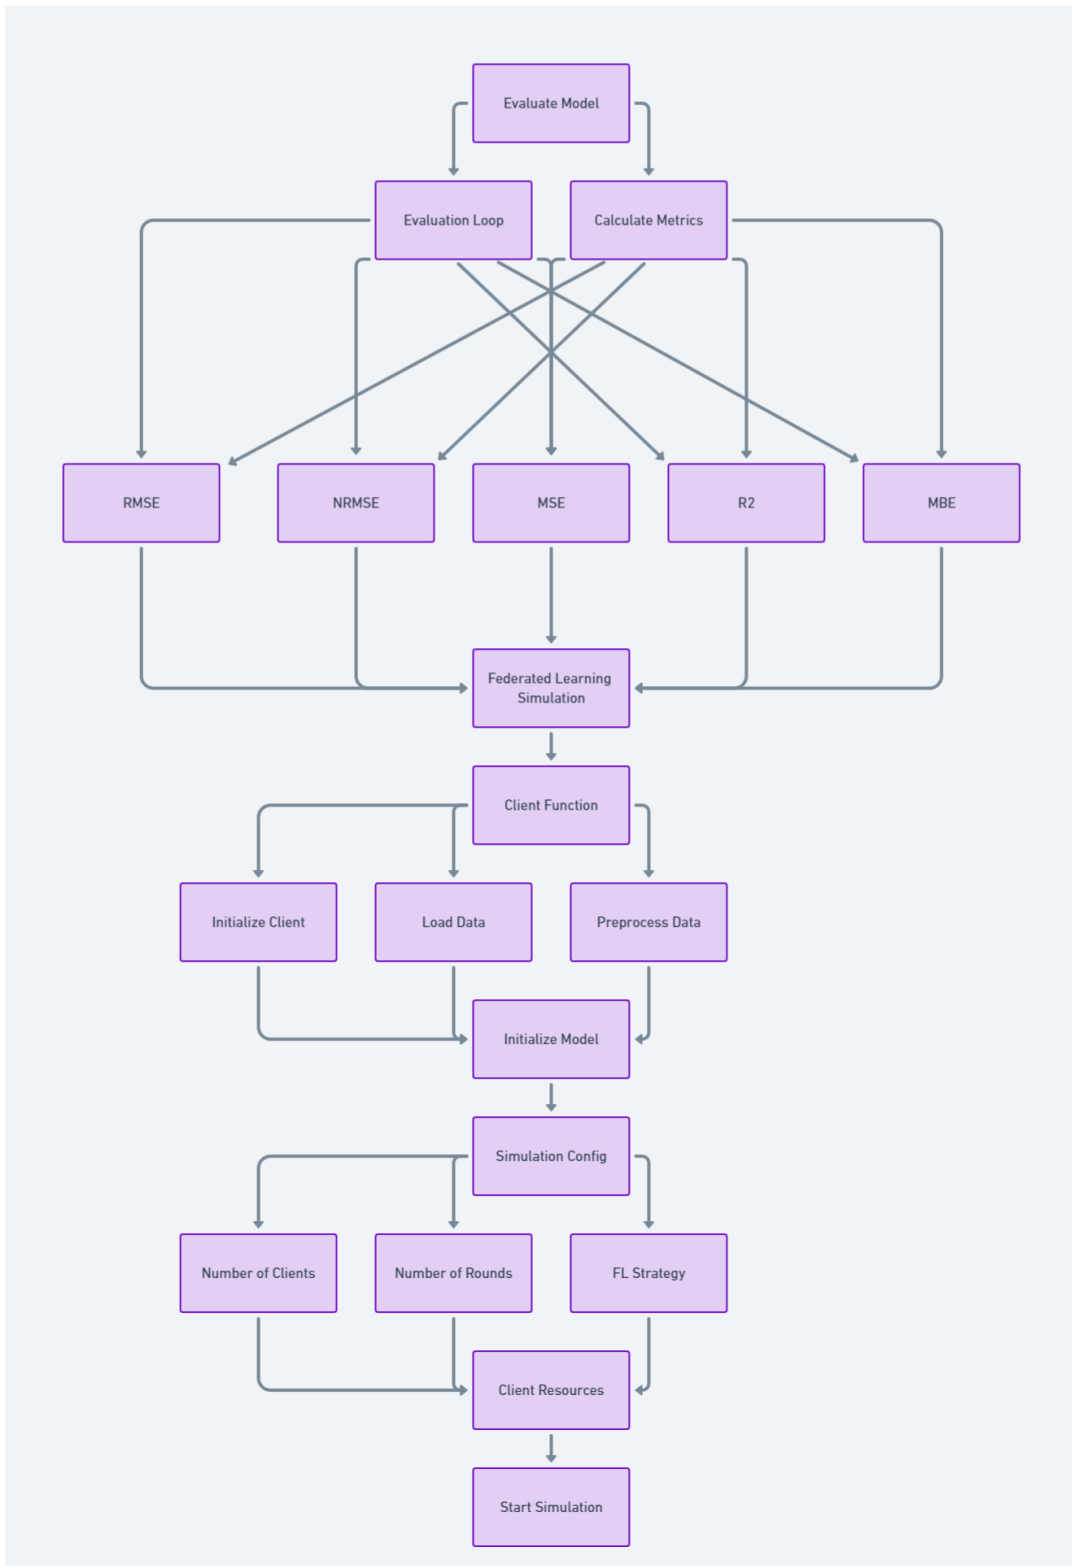
Εικόνα 18: Flower Client Implementation

Το παραπάνω διάγραμμα δείχνει σχηματικά την ροή της διαδικασίας για την δημιουργία των clients και την εκπαίδευση τους.



Εικόνα 19: Data Preparation to Create DataLoaders

Το παραπάνω διάγραμμα περιγράφει σχηματικά την ροή της διαδικασίας για την προεπεξεργασία των δεδομένων και την τελική δημιουργία των Train και Test DataLoaders.



Εικόνα 20: Procedure of Evaluation and Start of Simulation

Το παραπάνω διάγραμμα περιγράφει σχηματικά την ροή της διαδικασίας για την ρύθμιση των παραμέτρων για την έναρξη της προσομοίωσης και του προγράμματος, καθώς και την διαδικασία αξιολόγησης των αποτελεσμάτων.

5.3 Παρουσίαση και Ανάλυση Στρατηγικών Federated Learning

Η κοινή λογική όλων των στρατηγικών έγκειται στο ότι μετά την έναρξη της διαδικασίας εκπαίδευσης, ο κεντρικός διακομιστής αρχικοποιεί ένα συνολικό μοντέλο και το μεταδίδει σε όλους τους πελάτες. Στη συνέχεια, οι πελάτες ενημερώνουν τα ληφθέντα μοντέλα χρησιμοποιώντας ιδιωτικά δεδομένα και τα στέλνουν πίσω στον κεντρικό διακομιστή. Έπειτα, ξεκινάει η διαδικασία συγκέντρωσης και οι λαμβανόμενες ενημερώσεις μοντέλων συναθροίζονται με το παγκόσμιο μοντέλο και δημιουργείται ένα νέο παγκόσμιο μοντέλο που διανέμεται στους πελάτες-πηγές.

Τα ιδιαίτερα χαρακτηριστικά της καθεμιάς μπορούν να γίνουν αντιληπτά σχολιάζοντας ξεχωριστά την κάθε μία και εντοπίζοντας τις καίριες διαφορές τους προκειμένου να γίνει κατανοητή η λειτουργία τους. Πρόκειται για τις στρατηγικές FedAvg, FedProx, FedMedian, FaultTolerantFedAvg, FedAdam και FedYogi και παρακάτω αναλύονται και παρουσιάζονται οι ιδιαιτερότητες τους:

1. FedAvg (Federated Averaging):

- Μέθοδος συνάθροισης (Aggregation Method): Υπολογίζεται ο σταθμισμένος μέσος όρος των βαρών των ενημερώσεων μοντέλου από τους συμμετέχοντες πελάτες.
- Κανονικοποίηση (Regularization): Δεν εφαρμόζεται καμία ρητή κανονικοποίηση στις ενημερώσεις του μοντέλου.
- Ευστάθεια (Robustness): Ευάλωτη σε ακραίες τιμές στις ενημερώσεις των πελατών.
- Πλεονεκτήματα:
 - Απλή και ευρέως χρησιμοποιούμενη προσέγγιση.
 - Απλή υλοποίηση.
 - Αποτελεσματική σε πολλά σενάρια, ιδίως όταν οι κατανομές δεδομένων είναι παρόμοιες σε όλους τους πελάτες.
- Μειονεκτήματα:
 - Ευάλωτη σε ακραίες τιμές, οι οποίες μπορούν να επηρεάσουν σημαντικά το συνολικό μοντέλο.

- Μπορεί να υποστεί μείωση των επιδόσεων εάν οι πελάτες έχουν ετερογενή σύνολα δεδομένων ή παρουσιάζουν διαφορετικές συμπεριφορές.

2. FedProx (Federated Proximal):

- Μέθοδος συνάθροισης (Aggregation Method): Παρόμοια με την FedAvg, αλλά περιλαμβάνει έναν proximal όρο στη συνάρτηση απωλειών κατά τη διάρκεια της εκπαίδευσης για να «ενθαρρύνει» τις τοπικές παραμέτρους του μοντέλου να παραμένουν κοντά στις συνολικές παραμέτρους του μοντέλου.
- Κανονικοποίηση (Regularization): Εισάγει κανονικοποίηση μέσω του proximal όρου, ενισχύοντας την ευστάθεια έναντι των ενημερώσεων του πελάτη.
- Ευστάθεια (Robustness): Πιο ευσταθής σε ακραίες τιμές σε σύγκριση με το FedAvg λόγω της κανονικοποίησης.
- Πλεονεκτήματα:
 - Παρέχει ρητή κανονικοποίηση, η οποία μπορεί να βελτιώσει τη σύγκλιση και τη γενίκευση.
 - Βοηθά στον μετριασμό του αντίκτυπου των ακραίων τιμών, «τιμωρώντας» τις αποκλίσεις από το συνολικό μοντέλο.
 - Προσφέρει ευελιξία με την προσαρμογή του proximal όρου για τον έλεγχο της ισχύος της κανονικοποίησης.
- Μειονεκτήματα:
 - Απαιτεί πρόσθετη πολυπλοκότητα υλοποίησης για την ενσωμάτωση του proximal όρου στη συνάρτηση απώλειας.
 - Μπορεί να επιφέρει υπολογιστική επιβάρυνση λόγω του πρόσθετου υπολογισμού της κανονικοποίησης.

3. FedMedian (Federated Median):

- Μέθοδος συνάθροισης (Aggregation Method): Υπολογίζει τη διάμεσο των βαρών των ενημερώσεων του μοντέλου αντί του σταθμισμένου μέσου όρου που χρησιμοποιείται στο FedAvg.

- Κανονικοποίηση (Regularization): Δεν εφαρμόζεται καμία ρητή κανονικοποίηση στις ενημερώσεις του μοντέλου.
- Ευστάθεια (Robustness): Περισσότερο ευσταθής στις ακραίες τιμές σε σύγκριση με τη FedAvg λόγω της χρήσης της διαμέσου, αλλά λιγότερο ευσταθής από τη FedProx.
- Πλεονεκτήματα:
 - Ανθεκτικότητα σε ακραίες τιμές, καθώς οι ακραίες τιμές επηρεάζουν λιγότερο το τελικό συγκεντρωτικό μοντέλο.
 - Απλή και διαισθητική μέθοδος συνάθροισης, εύκολη στην εφαρμογή.
 - Μπορεί να χειριστεί ετερογενή σύνολα δεδομένων και συμπεριφορές πελατών πιο αποτελεσματικά από το FedAvg.
- Μειονεκτήματα:
 - Ενδέχεται να μην παρέχει τόσο ισχυρή κανονικοποίηση όσο η FedProx, ιδίως σε σενάρια με σημαντικά ακραίες τιμές.
 - Ενδέχεται να μην συγκλίνει τόσο γρήγορα όσο η FedProx λόγω της έλλειψης ρητής κανονικοποίησης.

4. FaultTolerantFedAvg:

- Μέθοδος συνάθροισης (Aggregation Method): Υπολογίζεται ο σταθμισμένος μέσος όρος των βαρών των ενημερώσεων μοντέλου από τους συμμετέχοντες πελάτες, παρόμοια με την FedAvg.
- Ανοχή Σφαλμάτων (Fault Tolerance): Εισάγει μηχανισμούς ανοχής σφαλμάτων για την αντιμετώπιση αποτυχιών κατά την διάρκεια των γύρων συνάθροισης.
- Ευστάθεια (Robustness): Λιγότερο ευάλωτη σε αποτυχίες, καθώς απαιτεί ελάχιστο ποσοστό ολοκλήρωσης για τη συνάθροιση.
- Πλεονεκτήματα:
 - Παρέχει ανοχή σφαλμάτων, διασφαλίζοντας ότι η συνάθροιση συνεχίζεται ακόμη και με την παρουσία αποτυχιών του πελάτη.

- Επιτρέπει την ευέλικτη διαμόρφωση των ποσοστών ολοκλήρωσης για τον έλεγχο του επιπέδου ανοχής.
- Διατηρεί την απλότητα του FedAvg, ενώ παράλληλα ενισχύει την ανθεκτικότητα.
- Μειονεκτήματα:
 - Μπορεί να εισάγει πρόσθετη επιβάρυνση λόγω της ανάγκης παρακολούθησης των ποσοστών ολοκλήρωσης και χειρισμού των αποτυχιών.
 - Απαιτείται προσεκτική ρύθμιση των ορίων του ποσοστού ολοκλήρωσης για την εξισορρόπηση της ανοχής σφαλμάτων και της απόδοσης.

5. FedAdam:

- Μέθοδος συνάθροισης (Aggregation Method): Υπολογίζεται ο σταθμισμένος μέσος όρος των βαρών των ενημερώσεων μοντέλου, παρόμοια με την FedAvg, αλλά με προσαρμογές ειδικά για την Adam.
- Προσαρμοστική βελτιστοποίηση (Adaptive Optimization): Χρησιμοποιείται ο βελτιστοποιητής Adam προκειμένου να προσαρμοστεί ο ρυθμός μάθησης του FL με βάση τις προηγούμενες κλίσεις. Εισάγονται όροι διόρθωσης μεροληψίας για να εξουδετερωθεί η επίδραση των εκτιμήσεων των αρχικών ροπών που είναι μεροληπτικές προς το μηδέν.
- Πολυπλοκότητα (Complexity): Εισάγεται πρόσθετη πολυπλοκότητα σε σύγκριση με τις βασικές στρατηγικές υπολογισμού του μέσου όρου, όπως η FedAvg.
- Πλεονεκτήματα:
 - Η προσαρμοστική βελτιστοποίηση μπορεί δυνητικά να οδηγήσει σε ταχύτερη σύγκλιση και βελτιωμένη απόδοση, ιδίως σε μη σταθερά περιβάλλοντα.
 - Διατηρείται η κατανομημένη φύση του FL, ενώ αξιοποιούνται προηγμένες τεχνικές βελτιστοποίησης.
- Μειονεκτήματα:

- Η αυξημένη πολυπλοκότητα μπορεί να απαιτεί περισσότερους υπολογιστικούς πόρους και προσεκτική ρύθμιση των παραμέτρων.
- Η προσαρμοστική φύση της βελτιστοποίησης μπορεί να εισάγει πρόσθετες προκλήσεις όσον αφορά τη σταθερότητα και τη σύγκλιση.

6. FedYogi:

- Μέθοδος συνάθροισης (Aggregation Method): Υπολογίζεται ο σταθμισμένος μέσος όρος των βαρών των ενημερώσεων μοντέλου, παρόμοια με την FedAvg, αλλά με προσαρμογές ειδικά για το Yogi.
- Προσαρμοστική βελτιστοποίηση (Adaptive Optimization): Χρησιμοποιείται ο βελτιστοποιητής Yogi προκειμένου να προσαρμοστεί ο ρυθμός μάθησης του FL με βάση τις προηγούμενες κλίσεις. Είναι παρόμοιο με το Adam αλλά με τροποποιήσεις για να χειρίζεται μη σταθερούς στόχους.
- Πολυπλοκότητα (Complexity): Παρόμοια με την FedAdam. Εισάγεται πρόσθετη πολυπλοκότητα σε σύγκριση με τις βασικές στρατηγικές υπολογισμού του μέσου όρου, όπως η FedAvg, ειδικά με την ενσωμάτωση προσαρμοστικών ρυθμών μάθησης και ορμής.
- Πλεονεκτήματα:
 - Η προσαρμοστική βελτιστοποίηση μπορεί δυνητικά να οδηγήσει σε ταχύτερη σύγκλιση και βελτιωμένη απόδοση, ιδίως σε μη σταθερά περιβάλλοντα.
 - Διατηρείται η κατανομημένη φύση του FL, ενώ αξιοποιούνται προηγμένες τεχνικές βελτιστοποίησης.
- Μειονεκτήματα:
 - Η αυξημένη πολυπλοκότητα μπορεί να απαιτεί περισσότερους υπολογιστικούς πόρους και προσεκτική ρύθμιση των παραμέτρων.
 - Η προσαρμοστική φύση της βελτιστοποίησης μπορεί να εισάγει πρόσθετες προκλήσεις όσον αφορά τη σταθερότητα και τη σύγκλιση.

Συνοψίζοντας, η FedProx προσφέρει ρητή κανονικοποίηση μέσω του proximal όρου, καθιστώντας την πιο ευσταθή στις ακραίες τιμές και μη-IID (Independent and Identically Distributed) δεδομένα σε σύγκριση με τις FedAvg και FedMedian. Αυτή η κανονικοποίηση μπορεί να μετριάσει τον αντίκτυπο των θορυβωδών ενημερώσεων πελατών, βελτιώνοντας τη συνολική απόδοση του μοντέλου. Η FedMedian παρέχει μια ισχυρή μέθοδο συνάθροισης υπολογίζοντας τη διάμεσο των ενημερώσεων του μοντέλου, η οποία μπορεί να είναι πιο ανθεκτική στις ακραίες τιμές σε σύγκριση με τον απλό μέσο όρο, αλλά δεν διαθέτει ρητή κανονικοποίηση. Ωστόσο, δεν διαθέτει ρητούς μηχανισμούς κανονικοποίησης όπως το FedProx, περιορίζοντας ενδεχομένως την ικανότητά του να χειρίζεται αποτελεσματικά ακραίες συμπεριφορές πελατών όπως και η FedAvg. Η FedAvg είναι μια απλή στρατηγική που συγκεντρώνει τις ενημερώσεις του μοντέλου ομοιόμορφα σε όλους τους συμμετέχοντες πελάτες, καθιστώντας την εύκολη στην υλοποίηση και υπολογιστικά αποδοτική. Ωστόσο, η απλότητα της μπορεί να την καταστήσει ευάλωτη σε ακραίες τιμές και σε κατανομές δεδομένων που δεν είναι IID. Το FaultTolerantFedAvg βασίζεται στο FedAvg ενσωματώνοντας μηχανισμούς ανοχής σφαλμάτων, εξασφαλίζοντας συνεχή πρόοδο ακόμη και με την παρουσία αποτυχιών του πελάτη. Αυτή η στρατηγική ενισχύει την αξιοπιστία των ομοσπονδιακών συστημάτων μάθησης, ιδίως σε κατανεμημένα περιβάλλοντα επιρρεπή σε σφάλματα επικοινωνίας ή αποτυχίες κόμβων. Τα FedAdam και FedYogi εισάγουν τεχνικές προσαρμοστικής βελτιστοποίησης, προσαρμόζοντας δυναμικά τους ρυθμούς μάθησης και τις παραμέτρους ορμής με βάση το ιστορικό των κλίσεων και των ενημερώσεων. Αυτές οι στρατηγικές προσφέρουν βελτιωμένες ιδιότητες σύγκλισης και ανθεκτικότητα σε μη σταθερούς στόχους, αλλά ενδέχεται να εισάγουν πρόσθετη υπολογιστική επιβάρυνση. Η επιλογή της στρατηγικής εξαρτάται από διάφορους παράγοντες όπως τα χαρακτηριστικά του συνόλου δεδομένων, η παρουσία ακραίων τιμών και οι επιθυμητοί συμβιβασμοί μεταξύ απλότητας, ευρωστίας και υπολογιστικής αποδοτικότητας. Ωστόσο στο παρόν έργο χρησιμοποιούνται όλες οι παραπάνω στρατηγικές για να μπορεί να επιτευχθεί η επιθυμητή σύγκριση μεταξύ των αποτελεσμάτων τους.

6 Αξιολόγηση Αποτελεσμάτων

6.1 Μετρικές Αξιολόγησης (Evaluation Metrics)

Οι μετρικές αξιολόγησης αποτελούν ένα από τα βασικότερα εργαλεία για την αξιολόγηση της απόδοσης και της ακρίβειας των προγνωστικών μοντέλων. Η συνδρομή τους είναι πολύτιμη, καθώς μπορούν να εκφράσουν σαν αριθμό ή ποσοστό την διαφορά μεταξύ των τιμών πρόβλεψης και των πραγματικών τιμών, δίνοντας την δυνατότητα αντίληψης της απόδοσης ενός μοντέλου. Γι' αυτό το λόγο αξιοποιούνται και στην παρούσα εργασία τέσσερις (4) από τις πιο συχνά χρησιμοποιούμενες μετρικές και συγκεκριμένα, το μέσο τετραγωνικό σφάλμα (Root Mean Square Error (RMSE)), το κανονικοποιημένο μέσο τετραγωνικό σφάλμα (Normalized Root Mean Square Error (nRMSE)), το μέσο σφάλμα μεροληψίας (Mean Bias Error (MBE)) και ο συντελεστής προσδιορισμού (Coefficient of Determination (R^2)). Κάθε μία από αυτές τις μετρικές παρέχει μοναδικές πληροφορίες σχετικά με την ακρίβεια και την αξιοπιστία του μοντέλου.

6.1.1 Root Mean Square Error (RMSE)

Το Root Mean Square Error (RMSE) [76] υπολογίζει το μέσο μέγεθος των σφαλμάτων μεταξύ των τιμών πρόβλεψης (\hat{y}_i) και των πραγματικών τιμών (y_i). Ορίζεται ως η τετραγωνική ρίζα των μέσων τετραγωνικών διαφορών μεταξύ των προβλέψεων και των πραγματικών παρατηρήσεων.

$$RMSE = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (\hat{y}_i - y_i)^2}$$

Όπου:

- n είναι ο αριθμός των παρατηρήσεων
- \hat{y}_i είναι η τιμή πρόβλεψης για την i -οστή παρατήρηση
- y_i είναι η πραγματική τιμή για την i -οστή παρατήρηση

Το RMSE παρέχει ένα δείκτη του μέσου μεγέθους σφάλματος και λόγω του τετραγωνισμού των διαφορών που υφίσταται στον μαθηματικό τύπο είναι ευαίσθητο στα μεγάλα σφάλματα.

6.1.2 Normalized Root Mean Square Error (nRMSE)

Το Normalized Root Mean Square Error (nRMSE) [76] δεν έχει διαστάσεις και επιτρέπει την εύκολη σύγκριση μεταξύ συνόλων δεδομένων ή μοντέλων με διαφορετικές κλίμακες. Μπορεί να κανονικοποιηθεί με διάφορους τρόπους οι οποίοι συνήθως είναι είτε το εύρος των παρατηρούμενων τιμών που ορίζεται ως η μέγιστη τιμή μείον την ελάχιστη τιμή ($y_{max} - y_{min}$).

$$nRMSE = \frac{RMSE}{y_{max} - y_{min}}$$

είτε ο μέσος όρος των παρατηρούμενων τιμών:

$$nRMSE = \frac{RMSE}{\hat{y}}$$

Η κανονικοποίηση συμβάλλει στη σύγκριση των επιδόσεων των μοντέλων σε διαφορετικές κλίμακες.

6.1.3 Mean Bias Error (MBE)

Το Mean Bias Error (MBE) [77] υπολογίζει τη μέση μεροληψία στις προβλέψεις. Δείχνει αν οι προβλέψεις υπερεκτιμούν ή υποεκτιμούν συστηματικά τις πραγματικές τιμές και δηλαδή αν το μοντέλο κλίνει προς μια τιμή της διάχυτης ηλιακής ακτινοβολίας.

$$MBE = \frac{1}{n} \cdot \sum_{i=1}^n (\hat{y}_i - y_i)$$

Θετικός αριθμός MBE υποδηλώνει συνολική υπερεκτίμηση από το μοντέλο, ενώ αρνητικός αριθμός MBE υποδηλώνει υποεκτίμηση. Η επιθυμητή τιμή είναι το μηδέν (0). Σε αντίθεση με το RMSE, το MBE μπορεί να δείξει αν οι προβλέψεις είναι μεροληπτικές, αλλά δεν αντικατοπτρίζει το μέγεθος των σφαλμάτων.

6.1.4 Coefficient of Determination (R^2)

Το Coefficient of Determination (R^2) [78] υπολογίζει το ποσοστό της διακύμανσης της εξαρτημένης μεταβλητής που μπορεί να προβλεφθεί από την ή τις ανεξάρτητες μεταβλητές.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Όπου:

- \bar{y} είναι ο μέσος όρος των πραγματικών τιμών

Οι τιμές του R^2 κυμαίνονται στο διάστημα τιμών μηδέν (0) έως ένα (1), όπου το μηδέν (0) υποδηλώνει ότι το μοντέλο δεν δικαιολογεί καμία μεταβλητότητα και διακύμανση και το ένα (1) υποδηλώνει τέλεια πρόβλεψη. Συνηθίζεται να εκφράζεται και σαν ποσοστό, με το 100% να αντιστοιχεί στην τέλεια πρόβλεψη.

6.1.5 Συμπεράσματα

Η κατανόηση των παραπάνω μετρικών αξιολόγησης είναι καίριας σημασίας για την επιλογή και τη βελτίωση των μοντέλων πρόβλεψης. Το RMSE παρέχει εικόνα του συνολικού μεγέθους σφάλματος, το nRMSE επιτρέπει συγκρίσεις σε διαφορετικές κλίμακες, το MBE αναδεικνύει τη συστηματική μεροληψία και το R^2 υποδεικνύει την επεξηγηματική δύναμη του μοντέλου. Μαζί, αυτές οι μετρικές προσφέρουν μια ολοκληρωμένη αξιολόγηση της απόδοσης ενός μοντέλου, καθοδηγώντας τις βελτιώσεις και εξασφαλίζοντας αξιόπιστες προβλέψεις.

6.2 Αποτελέσματα Προσομοίωσης και Πειραμάτων

Σε αυτό το μέρος της εργασίας θα αναλυθούν τα αποτελέσματα των εκτεταμένων προσομοιώσεων που πραγματοποιήθηκαν για την αξιολόγηση της πρόβλεψης της ισχύος των φωτοβολταϊκών συστημάτων με χρήση της τεχνικής του Federated Learning. Στο παρόν έργο χρησιμοποιούνται έξι (6) διαφορετικές στρατηγικές Federated Learning η κάθε μία με ιδιαίτερα χαρακτηριστικά και διαφορετικούς μηχανισμούς για την συγκέντρωση δεδομένων και την εκπαίδευση του μοντέλου. Οι στρατηγικές παρουσιάστηκαν αναλυτικά στην ενότητα 4.4 και είναι οι εξής:

- FedAvg (Federated Averaging)
- FedProx (Federated Proximal)
- FedMedian (Federated Median)
- FaultTolerantFedAvg
- FedAdam
- FedYogi

Στόχος των προσομοιώσεων που διεξάγονται στην εργασία είναι η αξιολόγηση της ακρίβειας, της αποτελεσματικότητας και της ευστάθειας κάθε στρατηγικής Federated Learning στα πλαίσια της πρόβλεψης φωτοβολταϊκής ισχύος που είναι

και ο απώτερος σκοπός του ερευνητικού έργου αυτού. Η σύγκριση των στρατηγικών, αποσκοπεί στον προσδιορισμό της καταλληλότερης προσέγγισης για την πρόβλεψη ισχύος φωτοβολταϊκών συστημάτων, δεδομένου των απαιτήσεων και των προβλημάτων που προκύπτουν στα περιβάλλοντα καταναμημένων δεδομένων. Τα αποτελέσματα των προσομοιώσεων προσφέρουν πολύτιμες πληροφορίες σχετικά με τα πλεονεκτήματα και τους περιορισμούς κάθε στρατηγικής Federated Learning, παρέχοντας μια ολοκληρωμένη κατανόηση της δυνατότητας εφαρμογής τους σε σενάρια του πραγματικού κόσμου.

Κάθε στρατηγική εφαρμόζεται σε επτά (7) σύνολα δεδομένων που αντιστοιχούν σε επτά (7) φωτοβολταϊκές εγκαταστάσεις, που κάθε μία έχει διαφορετική ονομαστική και μέγιστη ισχύ και βρίσκονται τοποθετημένες σε 4 πόλεις της χώρας της Πορτογαλίας, όπως έχει ήδη παρουσιαστεί στην ενότητα 5.2.1. Το μοντέλο προσομοίωσης εκπαιδεύεται σε δεδομένα διάρκειας ενός έτους για κάθε φωτοβολταϊκό και χρησιμοποιεί για να επιβεβαιώσει τις προβλέψεις την υπόλοιπη έκταση του συνόλου δεδομένων. Το σύνολο δοκιμής διαφέρει για κάθε φωτοβολταϊκό, όπως είναι αναμενόμενο.

Οι μετρικές που χρησιμοποιούνται για την αξιολόγηση των στρατηγικών, αναλύθηκαν παραπάνω και περιληπτικά είναι:

- RMSE (Root Mean Squared Error): μετρά την τυπική απόκλιση των προβλεπόμενων τιμών από τις πραγματικές τιμές.
- nRMSE (normalized RMSE): κανονικοποιημένη μορφή της RMSE για σύγκριση μεταξύ διαφορετικών μονάδων.
- MBE (Mean Bias Error): μετρά τη μέση απόκλιση των προβλεπόμενων τιμών από τις πραγματικές τιμές.
- R^2 (Coefficient of Determination): μετρά το ποσοστό της διακύμανσης των πραγματικών τιμών που εξηγείται από το μοντέλο.

Στη συνέχεια, παρουσιάζονται οι λεπτομερείς μετρήσεις επιδόσεων για κάθε φωτοβολταϊκό και για όλες τις στρατηγικές, προκειμένου να υπάρχει η δυνατότητα σύγκρισης και εξαγωγής συμπερασμάτων για την ακριβή και αποτελεσματική πρόβλεψη ισχύος φωτοβολταϊκών συστημάτων. Οι τιμές που θα παρουσιαστούν παρακάτω προκύπτουν ως η μέση τιμή, για κάθε μετρική, από είκοσι (20) γύρους επαναλήψεων εκπαίδευσης του μοντέλου.

6.2.1 Γενική Ανασκόπηση

PV	Metric	FedAvg	FaultTolerantFedAvg	FedProx	FedMedian	FedAdam	FedYogi
PV ₁	RMSE(KWh)	0.7557	0.7578	0.7737	0.7890	0.9463	0.8447
	MBE(KWh)	-0.1203	-0.0844	-0.1358	-0.1183	-0.0436	0.0495
	nRMSE(%)	31.85	32.02	32.61	33.25	39.88	35.60
	R ² (%)	89.3096	89.4075	88.9463	88.3672	81.3238	85.6079
PV ₂	RMSE(KWh)	2.7037	2.7327	2.7165	2.7314	3.0620	3.0891
	MBE(KWh)	-0.1186	-0.1075	-0.1021	-0.0577	0.0405	0.1809
	nRMSE(%)	24.25	24.51	24.36	24.49	27.46	27.70
	R ² (%)	94.0586	93.9479	94.0187	93.9235	91.8903	91.4203
PV ₃	RMSE(KWh)	12.3058	12.1027	11.9206	12.3221	13.7779	14.1038
	MBE(KWh)	-1.4992	-0.3439	-1.1837	-1.6660	-0.9917	0.0687
	nRMSE(%)	27.30	26.85	26.44	27.33	30.56	31.29
	R ² (%)	92.4521	92.7104	92.9213	92.3738	90.1194	88.5742
PV ₄	RMSE(KWh)	1.6702	1.6654	1.6307	1.6874	1.8974	1.9413
	MBE(KWh)	0.0926	0.0906	0.0506	0.1104	0.1633	0.2859
	nRMSE(%)	23.75	23.68	23.19	23.99	26.98	27.60
	R ² (%)	94.2682	94.3223	94.5528	94.1091	92.0832	91.3187
PV ₅	RMSE(KWh)	2.6753	2.674	2.6157	2.6850	3.1457	3.2367
	MBE(KWh)	-0.0383	-0.0313	-0.1444	0.0471	0.1930	0.3648
	nRMSE(%)	21.81	21.79	21.33	21.89	25.65	26.39
	R ² (%)	95.1629	95.1898	95.4020	95.0932	92.7598	91.8241
PV ₆	RMSE(KWh)	6.3461	6.2130	6.2007	6.2614	7.2198	7.3410
	MBE(KWh)	-0.9164	-0.5079	-0.7156	-0.7098	-0.4235	0.1501
	nRMSE(%)	24.93	24.40	24.36	24.59	28.36	28.83
	R ² (%)	93.6901	93.9868	94.0053	93.8041	91.3503	90.6546
PV ₇	RMSE(KWh)	2.6618	2.6753	2.6465	2.6952	3.1547	3.1924
	MBE(KWh)	-0.0052	-0.0081	-0.0043	0.0495	0.1919	0.3590
	nRMSE(%)	19.92	20.02	19.81	20.17	23.61	23.89
	R ² (%)	95.9814	95.9565	96.0387	95.8689	93.8274	93.2914

Πίνακας 3: Συνολική Παρουσίαση Αποτελεσμάτων των Προσομοιώσεων με τις Μετρικές RMSE, MBE, nRMSE και R² για όλες τις Στρατηγικές και όλα τα Φωτοβολταϊκά

Είναι σημαντικό να παρατηρηθεί ότι όλες οι στρατηγικές με μια πρώτη ματιά φαίνεται να είναι κοντά συγκριτικά. Ξεχωρίζουν ελάχιστα οι τρεις (3) πρώτες στήλες του πίνακα που περιλαμβάνουν τις FedAvg, FaultTolerantFedAvg και την FedProx στις οποίες διακρίνονται ελαφρώς καλύτερες επιδόσεις, σε αντιδιαστολή με την δεξιά μεριά του πίνακα που περιλαμβάνει τις στρατηγικές FedMedian, FedAdam και FedYogi. Για παράδειγμα, η FaultTolerantFedAvg έχει την καλύτερη τιμή MBE (-0.0313) στο φωτοβολταϊκό σύστημα PV₅, υποδεικνύοντας πολύ μικρή μέση μεροληψία. Παρόμοια, η στρατηγική FedAvg, στο PV₁, πετυχαίνει την χαμηλότερη τιμή nRMSE (31.85%) και στο PV₂ την υψηλότερη τιμή R² (94.0586), επιδεικνύοντας την υψηλή ακρίβεια και προσαρμογή του μοντέλου. Επιπλέον, η στρατηγική FedProx εμφανίζει συχνά τις χαμηλότερες τιμές RMSE, όπως στο PV₃

(11.9206) και στο PV₇ (2.6465), αναδεικνύοντας την ικανότητά της να παράγει ακριβείς προβλέψεις με ελάχιστη απόκλιση.

Αξιοσημείωτες είναι και οι διαφορές που παρουσιάζει στους δείκτες RMSE και MBE το φωτοβολταϊκό PV₃. Συγκεκριμένα οι τιμές του δείκτη RMSE είναι ιδιαίτερα υψηλές σε όλες τις στρατηγικές σε σχέση με τα υπόλοιπα φωτοβολταϊκά, ενώ οι τιμές του δείκτη MBE είναι αρκετά απομακρυσμένες από το επιθυμητό μηδέν (0) . Αυτό οφείλεται στην πολύ μικρή περίοδο αξιολόγησης (δοκιμής) του PV₃. Συγκεκριμένα, παρατηρώντας τους πίνακες 1 και 2 μόνο το 9.5% των 9670 γραμμών του συνόλου δεδομένων ανήκουν στο σύνολο δοκιμής του PV₃ και δηλαδή 910 προβλέψεις ωριαίων σημείων. Αυτό αντιστοιχεί σε 38 ημέρες όπως μπορούμε να δούμε και από τις ημερομηνίες, γνωρίζοντας ότι το σύνολο εκπαίδευσης αποτελείται από δεδομένα δώδεκα (12) μηνών. Επιπλέον, η αξιολόγηση διεξάγεται κυρίως τον μήνα του Μαρτίου όπου οι καιρικές συνθήκες δεν είναι ιδιαίτερα σταθερές και έτσι το μοντέλο πρόβλεψης αντιμετωπίζει δυσκολίες στο να είναι ακριβές.

Πολύ μικρή περίοδο αξιολόγησης διαθέτει και το φωτοβολταϊκό PV₁, του οποίου το σύνολο δεδομένων χρησιμοποιήθηκε σχεδόν εξ' ολοκλήρου για την εκπαίδευση του μοντέλου. Αυτό δικαιολογεί και την μικρή διαφορά που παρουσιάζει στον δείκτη R² σε σχέση με τα υπόλοιπα φωτοβολταϊκά, εμφανίζοντας ελαφρώς μειωμένα ποσοστά.

Παρακάτω εξετάζονται αναλυτικά τα αποτελέσματα της κάθε στρατηγικής για κάθε φωτοβολταϊκό ξεχωριστά ώστε να είναι εφικτή η πιο ενδελεχής μελέτη και για να καταστούν εμφανείς όλες οι διαφορές μεταξύ όλων των στρατηγικών και των φωτοβολταϊκών.

6.2.2 Ανάλυση ανά Φωτοβολταϊκό Σύστημα


Για το Φωτοβολταϊκό Σύστημα PV₁ :

Εξετάζοντας πιο προσεκτικά τον πίνακα αποτελεσμάτων

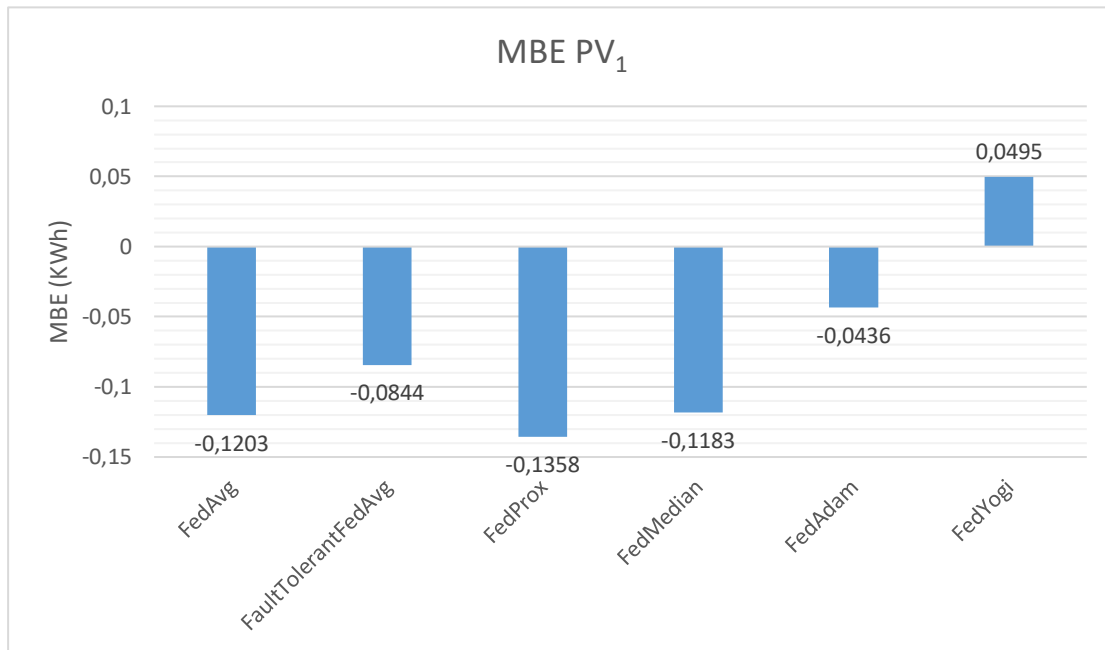
Metric	FedAvg	FaultTolerantFedAvg	FedProx	FedMedian	FedAdam	FedYogi
RMSE(KWh)	0.7557	0.7578	0.7737	0.7890	0.9463	0.8447
MBE(KWh)	-0.1203	-0.0844	-0.1358	-0.1183	-0.0436	0.0495
nRMSE(%)	31.85	32.02	32.61	33.25	39.88	35.60
R²(%)	89.3096	89.4075	88.9463	88.3672	81.3238	85.6079

Πίνακας 4: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV₁

Στο φωτοβολταϊκό PV₁, οι στρατηγικές FedAvg, FaultTolerantFedAvg και FedProx εμφανίζουν τις χαμηλότερες τιμές RMSE και nRMSE, υποδεικνύοντας υψηλή ακρίβεια στις προβλέψεις τους. Τα ποσοστά R² είναι επίσης υψηλά, πάνω από 89%, δείχνοντας την καλή προσαρμογή του μοντέλου. Η FedAdam έχει σχετικά χαμηλότερη απόδοση με υψηλότερη RMSE (0.9463 KWh) και χαμηλότερο R² (81.32%). Η FedAvg και η FaultTolerantFedAvg είναι οι καλύτερες επιλογές για το συγκεκριμένο φωτοβολταϊκό σύστημα.



Εικόνα 21: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₁ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi



Εικόνα 22: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₁ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi


Για το Φωτοβολταϊκό Σύστημα PV₂ :

Εξετάζοντας πιο προσεκτικά τον πίνακα αποτελεσμάτων


Metric	FedAvg	FaultTolerantFedAvg	FedProx	FedMedian	FedAdam	FedYogi
RMSE(KWh)	2.7037	2.7327	2.7165	2.7314	3.0620	3.0891
MBE(KWh)	-0.1186	-0.1075	-0.1021	-0.0577	0.0405	0.1809
nRMSE(%)	24.25	24.51	24.36	24.49	27.46	27.70
R²(%)	94.0586	93.9479	94.0187	93.9235	91.8903	91.4203

Πίνακας 5: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV₂

Στο φωτοβολταϊκό PV₂, οι στρατηγικές FedAvg, FaultTolerantFedAvg και FedProx εμφανίζουν επίσης τις καλύτερες επιδόσεις, με χαμηλές τιμές RMSE και nRMSE και υψηλά ποσοστά R². Αν και η FedAdam έχει τον καλύτερο δείκτη MBE πλησιάζοντας περισσότερο το μηδέν (0.0405), η FedAvg αποτελεί την ιδανική επιλογή για το συγκεκριμένο φωτοβολταϊκό σύστημα έχοντας τις καλύτερες επιδόσεις στις υπόλοιπες μετρικές.



Εικόνα 23: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₂ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi



Εικόνα 24: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₂ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi

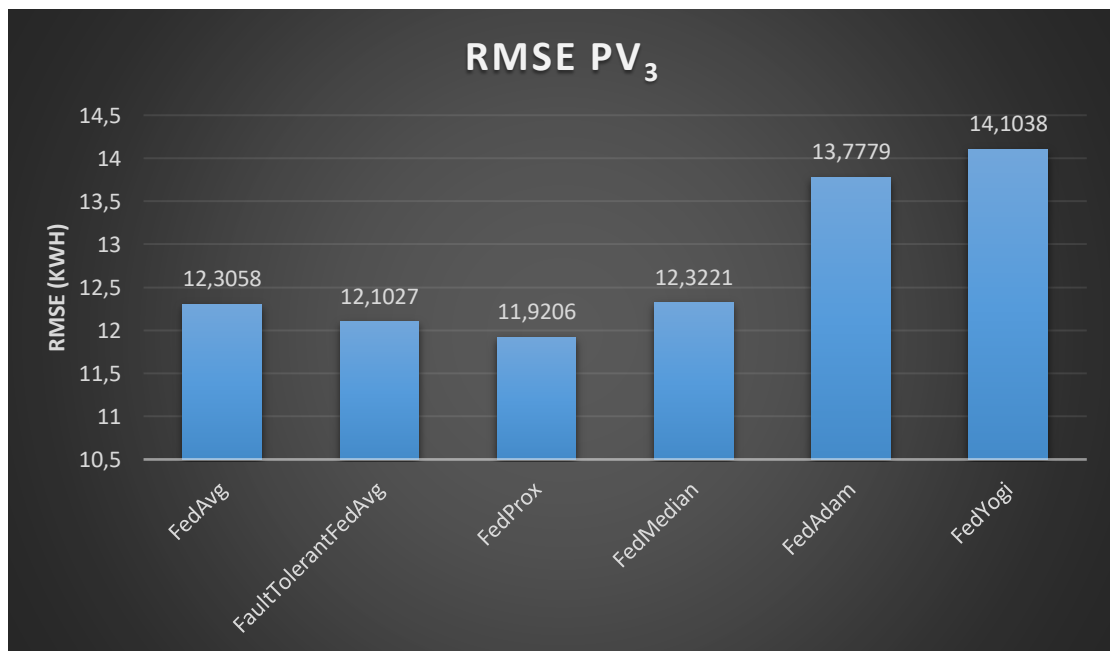
Για το Φωτοβολταϊκό Σύστημα PV₃ :

Εξετάζοντας πιο προσεκτικά τον πίνακα αποτελεσμάτων

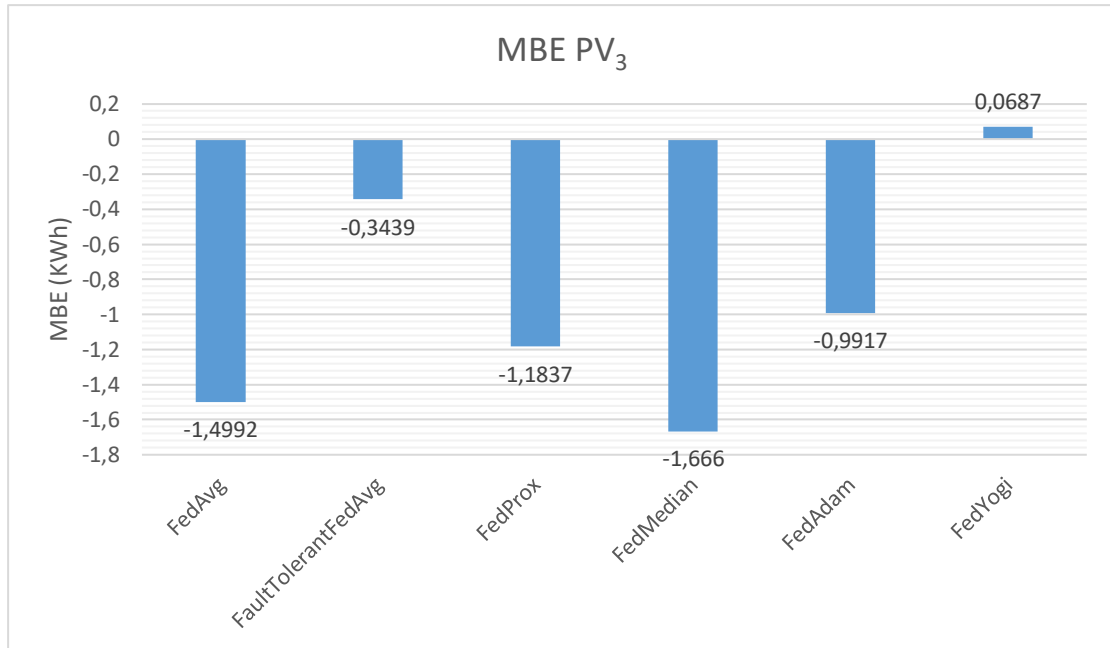
Metric	FedAvg	FaultTolerantFedAvg	FedProx	FedMedian	FedAdam	FedYogi
RMSE(KWh)	12.3058	12.1027	11.9206	12.3221	13.7779	14.1038
MBE(KWh)	-1.4992	-0.3439	-1.1837	-1.6660	-0.9917	0.0687
nRMSE(%)	27.30	26.85	26.44	27.33	30.56	31.29
R²(%)	92.4521	92.7104	92.9213	92.3738	90.1194	88.5742

Πίνακας 6: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV₃

Στο φωτοβολταϊκό PV₃, η FedProx έχει τη χαμηλότερη RMSE και την χαμηλότερη nRMSE (12.1027 και 26.44% αντίστοιχα), καθώς και υψηλό R² (92.92%). Τον καλύτερο δείκτη MBE έχει η FedYogi (0.0687), ωστόσο στις υπόλοιπες μετρικές υστερεί αρκετά. Η FaultTolerantFedAvg εμφανίζει επίσης καλές επιδόσεις, αν και λίγο χαμηλότερες από την FedProx. Επομένως η FedProx αποτελεί την ιδανική στρατηγική για το παρόν φωτοβολταϊκό σύστημα.



Εικόνα 25: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₃ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi



Εικόνα 26: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₃ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi


Για το Φωτοβολταϊκό Σύστημα PV₄ :

Εξετάζοντας πιο προσεκτικά τον πίνακα αποτελεσμάτων


Metric	FedAvg	FaultTolerantFedAvg	FedProx	FedMedian	FedAdam	FedYogi
RMSE(KWh)	1.6702	1.6654	1.6307	1.6874	1.8974	1.9413
MBE(KWh)	0.0926	0.0906	0.0506	0.1104	0.1633	0.2859
nRMSE(%)	23.75	23.68	23.19	23.99	26.98	27.60
R²(%)	94.2682	94.3223	94.5528	94.1091	92.0832	91.3187

Πίνακας 7: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV₄

Στο φωτοβολταϊκό PV₄, οι FedAvg, FaultTolerantFedAvg και FedProx εμφανίζουν εξαιρετικά κοντινές και καλές επιδόσεις, με χαμηλές τιμές RMSE και nRMSE και υψηλά ποσοστά R². Η FedYogi έχει τις χειρότερες επιδόσεις με υψηλές τιμές RMSE και χαμηλότερα ποσοστά R². Από την άλλη οι FedMedian και FedAdam κυμαίνονται κάπου στο ενδιάμεσο με μικρή διαφορά από τις τρεις (3) καλύτερες. Είναι εμφανές, ωστόσο, τόσο από τον πίνακα όσο και από τα διαγράμματα, ότι η καλύτερη συμπεριφορά είναι αυτή της FedProx παρουσιάζοντας τις καλύτερες επιδόσεις σε όλες τις μετρικές.



Εικόνα 27: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₄ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi



Εικόνα 28: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₄ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi


Για το Φωτοβολταϊκό Σύστημα PV₅ :

Εξετάζοντας πιο προσεκτικά τον πίνακα αποτελεσμάτων


Metric	FedAvg	FaultTolerantFedAvg	FedProx	FedMedian	FedAdam	FedYogi
RMSE(KWh)	2.6753	2.674	2.6157	2.6850	3.1457	3.2367
MBE(KWh)	-0.0383	-0.0313	-0.1444	0.0471	0.1930	0.3648
nRMSE(%)	21.81	21.79	21.33	21.89	25.65	26.39
R²(%)	95.1629	95.1898	95.4020	95.0932	92.7598	91.8241

Πίνακας 8: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV₅

Στο φωτοβολταϊκό PV₅, οι FedAvg, FaultTolerantFedAvg και FedProx έχουν εξαιρετικές και πολύ κοντινές επιδόσεις, με χαμηλές τιμές RMSE και nRMSE και υψηλά R². Η FedYogi βρίσκεται στο τέλος της κατάταξης, έχοντας υψηλότερες τιμές RMSE (3.2367) και χαμηλότερα ποσοστά R² (91.82% αντίστοιχα). Την πιο κοντινή στο μηδέν τιμή MBE (-0.0313) παρουσιάζει η FaultTolerantFedAvg, όμως η FedProx έχει τις καλύτερες επιδόσεις σε όλες τις άλλες μετρικές, γεγονός που την καθιστά την καταλληλότερη για αυτό το φωτοβολταϊκό σύστημα.



Εικόνα 29: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₅ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi



Εικόνα 30: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₅ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi


Για το Φωτοβολταϊκό Σύστημα PV₆ :

Εξετάζοντας πιο προσεκτικά τον πίνακα αποτελεσμάτων


Metric	FedAvg	FaultTolerantFedAvg	FedProx	FedMedian	FedAdam	FedYogi
RMSE(KWh)	6.3461	6.2130	6.2007	6.2614	7.2198	7.3410
MBE(KWh)	-0.9164	-0.5079	-0.7156	-0.7098	-0.4235	0.1501
nRMSE(%)	24.93	24.40	24.36	24.59	28.36	28.83
R²(%)	93.6901	93.9868	94.0053	93.8041	91.3503	90.6546

Πίνακας 9: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV₆

Στο φωτοβολταϊκό PV₆, η FedProx παρουσιάζει τις χαμηλότερες τιμές RMSE και nRMSE (6.2007 και 24.36%), καθώς και το υψηλότερο ποσοστό R² (94%). Ακολουθούν με πολύ κοντινές τιμές οι FaultTolerantFedAvg και FedMedian. Τις χειρότερες επιδόσεις εμφανίζουν οι FedAdam και FedYogi, των οποίων οι μετρήσεις απέχουν εμφανώς από τις υπόλοιπες στρατηγικές, έχοντας ουσιαστική διαφορά στα αποτελέσματα, με εξαίρεση την τιμή MBE (0.1501) της FedYogi η οποία πλησιάζει περισσότερο από όλες το μηδέν. Η FedProx αποτελεί και για αυτό το φωτοβολταϊκό σύστημα την ιδανική στρατηγική για εφαρμογή.



Εικόνα 31: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₆ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi



Εικόνα 32: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₆ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi

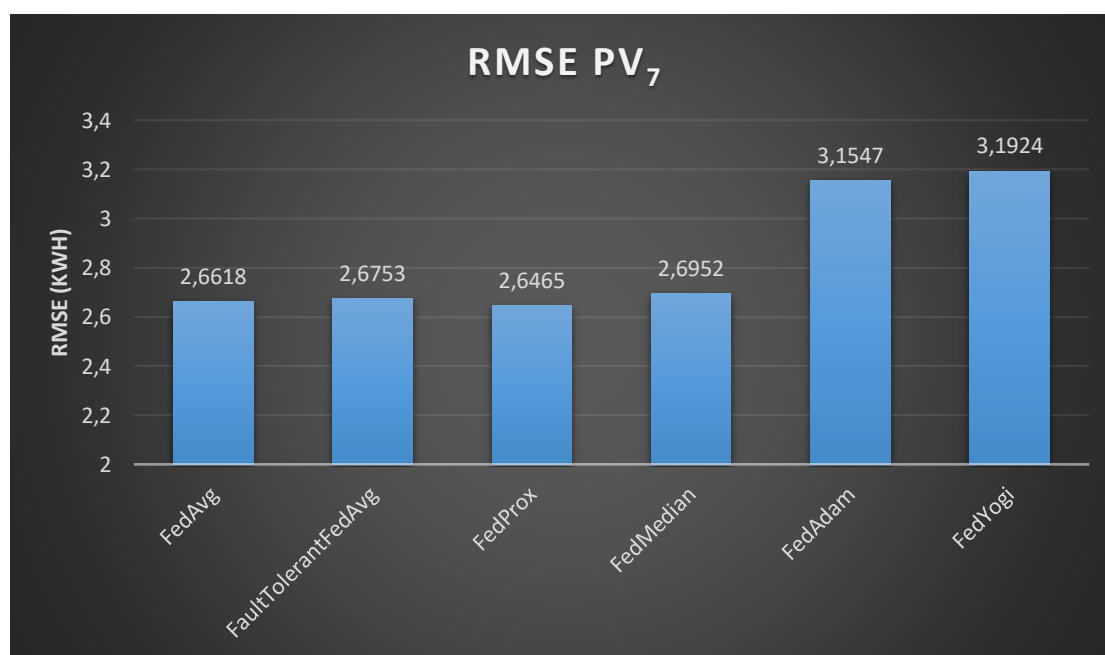
Για το Φωτοβολταϊκό Σύστημα PV₇ :

Εξετάζοντας πιο προσεκτικά τον πίνακα αποτελεσμάτων


Metric	FedAvg	FaultTolerantFedAvg	FedProx	FedMedian	FedAdam	FedYogi
RMSE(KWh)	2.6618	2.6753	2.6465	2.6952	3.1547	3.1924
MBE(KWh)	-0.0052	-0.0081	-0.0043	0.0495	0.1919	0.3590
nRMSE(%)	19.92	20.02	19.81	20.17	23.61	23.89
R²(%)	95.9814	95.9565	96.0387	95.8689	93.8274	93.2914

Πίνακας 10: Πίνακας Αποτελεσμάτων του Φωτοβολταϊκού Συστήματος PV₇

Στο φωτοβολταϊκό PV₇, η FedProx υποδεικνύει και πάλι τις καλύτερες επιδόσεις, με χαμηλά RMSE και nRMSE και υψηλό R². Την καλύτερη επίδοση έχει και στην μετρική MBE (-0.0043). Ακολουθείται από την FedAvg, με την οποία οι διαφορές είναι πολύ μικρές καθώς οι μετρήσεις τους είναι παρόμοιες όπως φαίνεται και στον πίνακα, ενώ την χειρότερη επίδοση έχει η FedYogi με σχετικά μικρές αποκλίσεις από τις υπόλοιπες.



Εικόνα 33: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₇ με την Τιμή RMSE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi



Εικόνα 34: Συγκριτικό Διάγραμμα για το Φωτοβολταϊκό Σύστημα PV₇ με την Τιμή MBE για τις Στρατηγικές FedAvg, FaultTolerantFedAvg, FedProx, FedMedian, FedAdam και FedYogi

6.3 Συμπεράσματα Αποτελεσμάτων

Από την αναλυτική εξέταση των αποτελεσμάτων, εύκολα διακρίνεται ότι οι πιο αξιόπιστες και σταθερές στρατηγικές είναι οι FedAvg, FaultTolerantFedAvg και FedProx. Είναι οι στρατηγικές που για τις περισσότερες φωτοβολταϊκές εγκαταστάσεις παρουσίασαν τις χαμηλότερες τιμές σφαλμάτων (RMSE, nRMSE και MBE) και τα υψηλότερα ποσοστά ακρίβειας (R^2). Συγκεκριμένα η FedProx είναι αυτή που ξεχωρίζει για τις περισσότερες φωτοβολταϊκές εγκαταστάσεις, σημειώνοντας τις καλύτερες επιδόσεις σε πέντε (5) από τα επτά (7) φωτοβολταϊκά συστήματα. Στον αντίποδα, οι στρατηγικές FedAdam και FedYogi παρουσίασαν σε γενικές γραμμές χαμηλές επιδόσεις με μεγάλη μεταβλητότητα, γεγονός που τις κατέστησε λιγότερο αποδοτικές και σαφώς λιγότερο κατάλληλες για τον στόχο του μοντέλου και δηλαδή την πρόβλεψη ενέργειας και ισχύος των φωτοβολταϊκών.

Συμπερασματικά, αναδεικνύεται η αξία και η κρισιμότητα της επιλογής κατάλληλης στρατηγικής εκπαίδευσης Federated Learning ανάλογα με τα ιδιαίτερα χαρακτηριστικά των φωτοβολταϊκών εγκαταστάσεων. Κάθε στρατηγική με τα πλεονεκτήματα και τα μειονεκτήματά της, έχει διαφορετική συμπεριφορά απέναντι στο εκάστοτε φωτοβολταϊκό σύστημα και επηρεάζει την ακρίβεια της πρόβλεψης.

Δεν πρέπει να αμεληθεί όμως και η γεωγραφική τοποθεσία των φωτοβολταϊκών συστημάτων, που ενδεχομένως να επηρεάσει σημαντικά την απόδοση του μοντέλου στις προβλέψεις, λόγω διαφορών σε κλιματικές συνθήκες, ηλιακή ακτινοβολία και άλλους τοπικούς παράγοντες.

Οι φωτοβολταϊκές εγκαταστάσεις είναι τοποθετημένες στις πόλεις Λισαβόνα, Φάρο, Μπράγκα και Σετουμπάλ της Πορτογαλίας, όπως έχει ήδη αναφερθεί, στις οποίες, όπως είναι αναμενόμενο, υπάρχουν διαφοροποιήσεις στα καιρικά περιβάλλοντα που τις επηρεάζουν. Ωστόσο στο παρόν έργο δεν φαίνεται η τοποθεσία των φωτοβολταϊκών σταθμών να επηρέασε σημαντικά τις προβλέψεις των στρατηγικών. Αξίζει να αναφερθεί ότι, με εξαίρεση το PV₃ που τα αποτελέσματά του επηρεάστηκαν αρκετά από το μέγεθος του συνόλου δοκιμής, για το οποίο έγινε λόγος εξ' αρχής, η μόνη διαφοροποίηση που εντοπίζεται στα φωτοβολταϊκά που βρίσκονται εκτός της πόλης της Λισαβόνας (PV₃, PV₅, PV₆) αφορά την φωτοβολταϊκή εγκατάσταση PV₆. Συγκεκριμένα, οι τιμές των δεικτών RMSE και MBE είναι ελαφρώς αυξημένες συγκριτικά με τα υπόλοιπα συστήματα και τα ποσοστά του δείκτη R^2 είναι αμυδρά χαμηλότερα, χωρίς όμως να είναι απογοητευτικά (Τα ποσοστά nRMSE δεν έχουν ιδιαίτερες διαφορές). Αυτό αποδεικνύει ότι η γεωγραφική τοποθεσία ενδέχεται να επηρεάζει έως ένα επίπεδο την ακρίβεια των προβλέψεων αλλά δεν αποτελεί ιδιαίτερα κρίσιμο παράγοντα για την ευστοχία των μοντέλων πρόβλεψης στη γενική περίπτωση.

7 Συμπεράσματα και Προτάσεις Μελλοντικής Εξέλιξης

7.1 Συμπεράσματα

Το παρόν έργο, πραγματεύεται την αξιοποίηση της τεχνικής του Federated Learning για την βραχυπρόθεσμη πρόβλεψη ισχύος φωτοβολταϊκών συστημάτων. Η πρόβλεψη ηλιακής ενέργειας και ισχύος αποτελεί ένα περίπλοκο εγχείρημα προς διερεύνηση, ιδιαίτερα όταν καλείται να αντιμετωπίσει και να καθησυχάσει τις ανησυχίες που αφορούν την προστασία των προσωπικών δεδομένων που διαθέτουν οι φωτοβολταϊκοί σταθμοί. Στα πλαίσια αυτά υλοποιήθηκε ένα Federated Learning Framework που διαθέτει ένα νευρωνικό δίκτυο LSTM και κάνοντας χρήση συνόλων δεδομένων από ηλιακούς σταθμούς μιας πορτογαλικής κοινότητας και καιρικών συνθηκών που συλλέχθηκαν από το Copernicus Atmosphere Data Store, αξιοποίησε έξι (6) διαφορετικές στρατηγικές Federated Learning για την εξαγωγή αποτελεσμάτων.

Κατά την προσπάθεια διεξαγωγής μιας ολοκληρωμένης μελέτης που περιβάλλει το ζητούμενο διερευνήθηκε ένα ευρύ φάσμα δεδομένων και μεθοδολογιών, ώστε να καταστεί εφικτή η κατανόηση του προβλήματος. Αναλύθηκε διεξοδικά η τεχνική του Federated Learning προκειμένου να υπάρχει η δυνατότητα αντιμετώπισης των προκλήσεων που ενδεχομένως να προέκυπταν και συζητήθηκαν οι διάφορες τεχνικές πρόβλεψης καταλήγοντας στην επιλογή του καταλληλότερου ANN (δηλαδή του LSTM) για την πρόβλεψη ισχύος στηριζόμενο σε σειριακά δεδομένα. Αφού επιλέχθηκε και παρουσιάστηκε το νευρωνικό δίκτυο, αναπτύχθηκε η μεθοδολογία της παρούσας εργασίας και υλοποιήθηκε το FL Framework που περιλαμβάνει σε γενικά πλαίσια τα στάδια της προεπεξεργασίας των δεδομένων, της επιλογής και της προσαρμογής της αρχιτεκτονικής του μοντέλου (LSTM), την ρύθμιση του Federated Learning καθώς και την διαδικασία εκπαίδευσης του μοντέλου ώστε να ολοκληρωθεί πλήρως η διαδικασία και να εξαχθούν αποτελέσματα.

Τα αποτελέσματα που προέκυψαν και αναλύθηκαν στα προηγούμενα κεφάλαια παρουσιάζουν ιδιαίτερο ενδιαφέρον, τόσο λόγω της απόκρισης των στρατηγικών σύγκλισης στην ποικιλομορφία και την ετερογένεια των δεδομένων μεταξύ των φωτοβολταϊκών εγκαταστάσεων, όσο και λόγω της διαφορετικής απόκρισης των στρατηγικών σύγκλισης στα δεδομένα του ίδιου φωτοβολταϊκού συστήματος. Συγκεκριμένα, οι στρατηγικές FL που επιλέχθηκαν, διατηρώντας το απόρρητο των δεδομένων, ανέπτυξαν διαφορετική συμπεριφορά απέναντι στα δεδομένα των φωτοβολταϊκών εγκαταστάσεων και με τις μετρικές αξιολόγησης κατέστη δυνατή η σύγκριση τους. Όλες οι στρατηγικές λειτούργησαν αποδοτικά χωρίς την

ακατέργαστη ανταλλαγή δεδομένων, με την FedProx να ξεχωρίζει για τις επιδόσεις της, παρουσιάζοντας εξαιρετική απόδοση ακρίβειας και χαμηλές τιμές σφαλμάτων σύμφωνα με τους δείκτες RMSE, nRMSE, MBE και R^2 . Τα αποτελέσματα των πειραμάτων από τις διάφορες στρατηγικές δεν επηρεάστηκαν από τον γεωγραφικό τόπο εγκατάστασης των φωτοβολταϊκών (τέσσερις διαφορετικές πόλεις της Πορτογαλίας), αλλά το μέγεθος του διαθέσιμου συνόλου δεδομένων φάνηκε να έχει αντίκτυπο. Το φωτοβολταϊκό σύστημα PV₃ το οποίο διαθέτει το μικρότερο σύνολο αξιολόγησης, προκάλεσε σε όλες τις στρατηγικές ελαφρά χειρότερες επιδόσεις, επιδεικνύοντας την σημασία που έχει για την αποτελεσματικότητα και την ακρίβεια των προβλέψεων των στρατηγικών, η εκτενής εκπαίδευση και δοκιμή τους.

Η παρούσα εργασία παρέχει χρήσιμες γνώσεις και επιβεβαιώνει ότι το Federated Learning είναι μια αποτελεσματική προσέγγιση για την πρόβλεψη της ισχύος των φωτοβολταϊκών. Η διατήρηση του απορρήτου των δεδομένων χωρίς να διακυβεύεται η ακρίβεια της πρόβλεψης αποτελεί σημαντικό βήμα προόδου για τον τομέα των ανανεώσιμων πηγών ενέργειας. Η έρευνα που διεξήχθη αντιμετώπισε τις ανησυχίες για την προστασία της ιδιωτικότητας των δεδομένων και με την σύγκριση πολλαπλών στρατηγικών FL παρείχε ένα εύρωστο πλαίσιο για ανάλυση, αποδεικνύοντας πόσο ουσιαστική και καιρία είναι η επιλογή της ιδανικής στρατηγικής FL σύμφωνα με τα χαρακτηριστικά των φωτοβολταϊκών εγκαταστάσεων.

7.2 Προτάσεις Μελλοντικής Εξέλιξης

Καθώς ο κόσμος κινείται προς την κατεύθυνση της αυξημένης υιοθέτησης των ανανεώσιμων πηγών ενέργειας, οι μέθοδοι και τα ευρήματα που παρουσιάζονται στην παρούσα διατριβή αποτελούν την λύση για πιο ασφαλή, αποδοτικά και αξιόπιστα συστήματα πρόβλεψης ισχύος, δημιουργώντας την βάση για μελλοντικές εξελίξεις στο αντικείμενο αυτό. Το έργο αυτό δημιουργεί πρόσφορο έδαφος για περαιτέρω καινοτομία, διασφαλίζοντας ότι η μετάβαση στις ανανεώσιμες πηγές ενέργειας θα είναι τόσο τεχνολογικά προηγμένη όσο και ηθικά ορθή. Ορισμένες προτάσεις μελλοντικής εξέλιξης παρουσιάζονται παρακάτω:

Παρά το γεγονός ότι στο παρόν έργο αξιοποιήθηκαν έξι (6) στρατηγικές Federated Learning, οι μελλοντικές έρευνες έχουν την δυνατότητα να διερευνήσουν επιπλέον στρατηγικές ή και υβριδικά μοντέλα αυτών συνδυάζοντας τα χαρακτηριστικά τουλάχιστον δύο (2) εκ των ήδη υπαρχόντων. Ένα υβριδικό μοντέλο μπορεί να εκμεταλλεύεται τα πλεονεκτήματα των επιλεγμένων στρατηγικών και να περιορίζει σημαντικά τις αδυναμίες που θα εμφάνιζαν αν εφαρμόζονταν αυτόνομα.

Εκτός του νευρωνικού δικτύου μακράς βραχυπρόθεσμης μνήμης (LSTM) άλλα μοντέλα μηχανικής μάθησης και τεχνικών νευρωνικών δικτύων θα μπορούσαν να εφαρμοστούν στο πλαίσιο του Federated Learning για την πρόβλεψη ισχύος φωτοβολταϊκών συστημάτων. Ήδη υπάρχουν μελέτες που χρησιμοποιούν μοντέλα διαφορετικά του LSTM, όμως η ποικιλία και το πλήθος των νευρωνικών δικτύων επιτρέπουν την περαιτέρω διερεύνηση, με χρήση τόσο μεμονωμένων μοντέλων, όσο και υβριδικών συνδυασμών αυτών. Μοντέλα όπως τα συνελκτικά νευρωνικά δίκτυα (CNNs), τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNNs), οι ελεγχόμενες επαναλαμβανόμενες μονάδες (GRUs) και τα μοντέλα που βασίζονται σε μετασχηματιστές θα μπορούσαν να προσφέρουν μοναδικά πλεονεκτήματα και η αξιολόγηση τους να συμβάλλει στην εύρεση των καλύτερων εργαλείων για διαφορετικά σενάρια πρόβλεψης.

Πέρα από την εναλλαγή στρατηγικών και νευρωνικών δικτύων για την εκπαίδευση, η επέκταση της διάρκειας και της κλίμακας των μελετών θα μπορούσε να αποφέρει καρπούς και θα παρείχε πιο ολοκληρωμένες γνώσεις. Η διεξαγωγή μακροχρόνιων πειραμάτων με πολυετή σύνολα δεδομένων, από μεγαλύτερο αριθμό φωτοβολταϊκών συστημάτων και σε διαφορετικές κλιματικές και γεωγραφικές περιοχές θα βοηθούσε στην κατανόηση της μακροπρόθεσμης αξιοπιστίας των στρατηγικών Federated Learning. Μελέτες με αυτή την θεματολογία συμβάλλουν στην ανάδειξη των εποχιακών τάσεων και τον αντίκτυπο των κλιματικών ανωμαλιών καθώς και σε άλλους παράγοντες που μπορεί να επηρεάζουν την ακρίβεια της πρόβλεψης.

Τέλος, οι αρχές και οι μεθοδολογίες που αναπτύχθηκαν στην παρούσα έρευνα μπορούν να εφαρμοστούν σε άλλους τομείς πρόβλεψης ανανεώσιμων πηγών ενέργειας, όπως η αιολική και η υδροηλεκτρική ενέργεια. Η εφαρμογή των στρατηγικών Federated Learning σε διαφορετικούς τύπους δεδομένων ανανεώσιμης ενέργειας μπορεί να αποτελέσει αντικείμενο προς διερεύνηση για μελλοντικές μελέτες ώστε να επικυρωθεί η ευελιξία του Federated Learning. Τέτοιες μελέτες θα μπορούσαν να συμβάλλουν σε μια ολοκληρωμένη πρόταση για την διασφάλιση της προστασίας των ιδιωτικών δεδομένων στην πρόβλεψη ενέργειας γενικότερα.

8 Βιβλιογραφία

- [1] United Nations, “What is Renewable Energy?,” *United Nations*, 2024. <https://www.un.org/en/climatechange/what-is-renewable-energy>
- [2] IEA, “Solar PV,” *International Energy Agency*, 2023. <https://www.iea.org/energy-system/renewables/solar-pv>
- [3] “ELECTRICITY GRID RESILIENCE Climate Change Is Expected to Have Farreaching Effects and DOE and FERC Should Take Actions Accessible Version Report to Congressional Requesters United States Government Accountability Office,” 2021. Available: <https://www.gao.gov/assets/720/712874.pdf>
- [4] C. Beaumont, S. Makridakis, S. C. Wheelwright, and V. E. McGee, “Forecasting: Methods and Applications,” *The Journal of the Operational Research Society*, vol. 35, no. 1, p. 79, Jan. 1984, doi: <https://doi.org/10.2307/2581936>.
- [5] D. Markovics and M. J. Mayer, “Comparison of machine learning methods for photovoltaic power forecasting based on numerical weather prediction,” *Renewable and Sustainable Energy Reviews*, vol. 161, p. 112364, 2022, doi: <https://doi.org/10.1016/j.rser.2022.112364>.
- [6] K. L. Jørgensen and H. R. Shaker, “Wind Power Forecasting Using Machine Learning: State of the Art, Trends and Challenges,” *IEEE Xplore*, Aug. 01, 2020. <https://ieeexplore.ieee.org/document/9181870>
- [7] M. J. Mayer, “Benefits of physical and machine learning hybridization for photovoltaic power forecasting,” *Renewable and Sustainable Energy Reviews*, vol. 168, p. 112772, Oct. 2022, doi: <https://doi.org/10.1016/j.rser.2022.112772>.
- [8] H. Hewamalage, C. Bergmeir, and K. Bandara, “Recurrent Neural Networks for Time Series Forecasting: Current status and future directions,” *International Journal of Forecasting*, vol. 37, no. 1, pp. 388–427, Jan. 2021, doi: <https://doi.org/10.1016/j.ijforecast.2020.06.008>.
- [9] I. Koprinska, D. Wu, and Z. Wang, “Convolutional Neural Networks for Energy Time Series Forecasting,” *IEEE Xplore*, Jul. 01, 2018. https://ieeexplore.ieee.org/abstract/document/8489399?casa_token=rSvse_mZz54AAAA:sWXSv2WTsTWSvleJn6LjqKgHED3cBL-Qc5t9NPkJhniDM-y04v1O90mwVbUBxrLX6Ez0nwSjWAM
- [10] S. Singh, “Deep-Learning for Time Series Forecasting: LSTM and CNN Neural Network,” *Medium*, Jan. 03, 2023. <https://medium.com/@sandha.iitr/deep-learning-for-time-series-forecasting-lstm-and-cnn-neur-4c934cb16707> (accessed Jul. 05, 2024).

- [11] GDPR, “General data protection regulation (GDPR),” *General Data Protection Regulation (GDPR)*, 2018. <https://gdpr-info.eu/>
- [12] U.S. Department of Health & Human Services, “Health Information Privacy,” *HHS.gov*, 2019. <https://www.hhs.gov/hipaa/index.html>
- [13] Wikipedia Contributors, “Federated learning,” *Wikipedia*, Dec. 03, 2019. https://en.wikipedia.org/wiki/Federated_learning
- [14] T. Sun, D. Li, and B. Wang, “Decentralized Federated Averaging,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 45, no. 4, pp. 4289–4301, Apr. 2023, doi: <https://doi.org/10.1109/TPAMI.2022.3196503>.
- [15] T. Vaj, “The difference between differential privacy and federated learning,” *Medium*, Dec. 14, 2023. <https://vtiya.medium.com/the-difference-between-differential-privacy-and-federated-learning-6cbe19333c09>
- [16] K. Bonawitz *et al.*, “Practical Secure Aggregation for Privacy-Preserving Machine Learning.” Available: <https://eprint.iacr.org/2017/281.pdf>
- [17] Y. Cho, J. Wang, and G. Joshi, “Towards Understanding Biased Client Selection in Federated Learning.” Accessed: Jul. 05, 2024. [Online]. Available: <https://proceedings.mlr.press/v151/jee-cho22a/jee-cho22a.pdf>
- [18] Journal Of L A T E X Class and Files, “FedLALR: Client-Specific Adaptive Learning Rates Achieve Linear Speedup for Non-IID Data,” vol. 14, no. 8, 2015, Accessed: Jul. 05, 2024. [Online]. Available: <https://arxiv.org/pdf/2309.09719.pdf>
- [19] A. Imteaj, U. Thakker, S. Wang, J. Li, and M. H. Amini, “A Survey on Federated Learning for ResourceConstrained IoT Devices,” *IEEE Internet of Things Journal*, vol. 9, no. 1, pp. 1–24, doi: <https://doi.org/10.1109/JIOT.2021.3095077>.
- [20] J. Konečný, H. McMahan, F. Yu, A. Theertha, D. Google, and P. Richtárik, “FEDERATED LEARNING: STRATEGIES FOR IMPROVING COMMUNICATION EFFICIENCY.” Available: <https://arxiv.org/pdf/1610.05492.pdf>
- [21] K. Bonawitz *et al.*, “TOWARDS FEDERATED LEARNING AT SCALE: SYSTEM DESIGN.” Available: <https://arxiv.org/pdf/1902.01046.pdf>
- [22] T. Li, A. K. Sahu, A. Talwalkar, and V. Smith, “Federated Learning: Challenges, Methods, and Future Directions,” *IEEE Signal Processing Magazine*, vol. 37, no. 3, pp. 50–60, May 2020, doi: <https://doi.org/10.1109/msp.2020.2975749>.
- [23] H. Zang *et al.*, “Hybrid method for short-term photovoltaic power forecasting based on deep convolutional neural network,” *IET Generation, Transmission & Distribution*, vol. 12, no. 20, pp. 4557–4567, Sep. 2018, doi: <https://doi.org/10.1049/iet-gtd.2018.5847>.

- [24] A. Jakoplić, D. Franković, V. Kirinčić, and T. Plavšić, “Benefits of short-term photovoltaic power production forecasting to the power system,” *Optimization and Engineering*, vol. 22, no. 1, pp. 9–27, Nov. 2020, doi: <https://doi.org/10.1007/s11081-020-09583-y>.
- [25] M. Massaoudi, I. Chihi, H. Abu-Rub, S. S. Refaat, and F. S. Oueslati, “Convergence of Photovoltaic Power Forecasting and Deep Learning: State-of-Art Review,” *IEEE Access*, vol. 9, pp. 136593–136615, 2021, doi: <https://doi.org/10.1109/access.2021.3117004>.
- [26] W. Samek, G. Montavon, A. Vedaldi, L. K. Hansen, and K.-R. Müller, *Explainable AI: Interpreting, Explaining and Visualizing Deep Learning*. Springer Nature, 2019. Accessed: Jul. 05, 2024. [Online]. Available: https://books.google.gr/books?hl=el&lr=&id=j5yuDwAAQBAJ&oi=fnd&pg=PR5&ots=Ir3VUu7R4K&sig=C5dzvj-XZ5nPcQpw4MMcympCo8&redir_esc=y#v=onepage&q&f=false
- [27] T. Li, A. K. Sahu, A. Talwalkar, and V. Smith, “Federated Learning: Challenges, Methods, and Future Directions,” *IEEE Signal Processing Magazine*, vol. 37, no. 3, pp. 50–60, May 2020, doi: <https://doi.org/10.1109/msp.2020.2975749>.
- [28] P. Hosseini, S. Taheri, J. Akhavan, and A. Razban, “Privacy-preserving federated learning: Application to behind-the-meter solar photovoltaic generation forecasting,” *Energy Conversion and Management*, vol. 283, p. 116900, 2023, doi: <https://doi.org/10.1016/j.enconman.2023.116900>.
- [29] B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y Arcas, “Communication-Efficient Learning of Deep Networks from Decentralized Data,” *proceedings.mlr.press*, Apr. 10, 2017. <https://proceedings.mlr.press/v54/mcmahan17a?ref=https://githubhelp.com>
- [30] I. Kaaya and J. Ascencio-Vásquez, *Photovoltaic Power Forecasting Methods*. IntechOpen, 2021. Available: <https://www.intechopen.com/chapters/76055>
- [31] W.-C. Tsai, C.-S. Tu, C.-M. Hong, and W.-M. Lin, “A Review of State-of-the-Art and Short-Term Forecasting Models for Solar PV Power Generation,” *Energies*, vol. 16, no. 14, p. 5436, Jan. 2023, doi: <https://doi.org/10.3390/en16145436>.
- [32] D. Sera, R. Teodorescu, and P. Rodriguez, “PV panel model based on datasheet values,” *IEEE Xplore*, Jun. 01, 2007. <https://ieeexplore.ieee.org/document/4374981>
- [33] J. Kleissl, *Solar Energy Forecasting and Resource Assessment*. Elsevier, 2013. doi: <https://doi.org/10.1016/c2011-0-07022-9>.

- [34] A. Mellit and S. A. Kalogirou, “Artificial intelligence techniques for photovoltaic applications: A review,” *Progress in Energy and Combustion Science*, vol. 34, no. 5, pp. 574–632, Oct. 2008, doi: <https://doi.org/10.1016/j.pecs.2008.01.001>.
- [35] H. Wen *et al.*, “A solar forecasting framework based on federated learning and distributed computing,” *Building and Environment*, vol. 225, p. 109556, 2022, doi: <https://doi.org/10.1016/j.buildenv.2022.109556>.
- [36] P. Hosseini, S. Taheri, J. Akhavan, and A. Razban, “Privacy-preserving federated learning: Application to behind-the-meter solar photovoltaic generation forecasting,” *Energy Conversion and Management*, vol. 283, p. 116900, 2023, doi: <https://doi.org/10.1016/j.enconman.2023.116900>.
- [37] W. Fu *et al.*, “A Spatiotemporal Federated Learning Based Distributed Photovoltaic Ultra-short-term Power Forecasting Method,” May 2023, doi: <https://doi.org/10.1109/icps57144.2023.10142102>.
- [38] A. Moradzadeh, H. Moayyed, B. Mohammadi-Ivatloo, Z. Vale, C. Ramos, and R. Ghorbani, “A novel cyberResilient solar power forecasting model based on secure federated deep learning and data visualization,” *Renewable Energy*, vol. 211, pp. 697–705, 2023, doi: <https://doi.org/10.1016/j.renene.2023.04.055>.
- [39] Wikipedia Contributors, “Long short-term memory,” *Wikipedia*, Nov. 22, 2018. https://en.wikipedia.org/wiki/Long_short-term_memory
- [40] E. Lorenz, T. Scheidsteger, Johannes Hurka, D. Heinemann, and C. Kurz, “Regional PV power prediction for improved grid integration,” vol. 19, no. 7, pp. 757–771, Nov. 2011, doi: <https://doi.org/10.1002/pip.1033>.
- [41] P. Bacher, H. Madsen, and H. A. Nielsen, “Online short-term solar power forecasting,” *Solar Energy*, vol. 83, no. 10, pp. 1772–1783, 2009, doi: <https://doi.org/10.1016/j.solener.2009.05.016>.
- [42] C. Chen, S. Duan, T. Cai, and B. Liu, “Online 24-h solar power forecasting based on weather type classification using artificial neural network,” *Solar Energy*, vol. 85, no. 11, pp. 2856–2870, Nov. 2011, doi: <https://doi.org/10.1016/j.solener.2011.08.027>.
- [43] A. Sleiman and W. Su, “Combined K-Means Clustering with Neural Networks Methods for PV Short-Term Generation Load Forecasting in Electric Utilities,” *Energies*, vol. 17, no. 6, pp. 1433–1433, Mar. 2024, doi: <https://doi.org/10.3390/en17061433>.
- [44] N. Aksoy and I. Genc, “Predictive models development using gradient boosting based methods for solar power plants,” *Journal of Computational Science*, vol. 67, p. 101958, Mar. 2023, doi: <https://doi.org/10.1016/j.jocs.2023.101958>.

- [45] B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y Arcas, “Communication-Efficient Learning of Deep Networks from Decentralized Data,” *proceedings.mlr.press*, Apr. 10, 2017. <http://proceedings.mlr.press/v54/mcmahan17a.html>
- [46] Q. Yang, Y. Liu, T. Chen, and Y. Tong, “Federated Machine Learning: Concept and Applications,” *arXiv.org*, 2019. <https://arxiv.org/abs/1902.04885>
- [47] J. Qian *et al.*, “Federated Reinforcement Learning for Electric Vehicles Charging Control on Distribution Networks,” *IEEE internet of things journal*, vol. 11, no. 3, pp. 5511–5525, Feb. 2024, doi: <https://doi.org/10.1109/jiot.2023.3306826>.
- [48] H. Wen *et al.*, “A solar forecasting framework based on federated learning and distributed computing,” *Building and Environment*, vol. 225, p. 109556, Nov. 2022, doi: <https://doi.org/10.1016/j.buildenv.2022.109556>.
- [49] H. Wang *et al.*, “Novel PV Power Hybrid Prediction Model Based on FL Co-Training Method,” *Electronics*, vol. 12, no. 3, p. 730, Jan. 2023, doi: <https://doi.org/10.3390/electronics12030730>.
- [50] “What is Python? Executive Summary,” *Python.org*, 2019. <https://www.python.org/doc/essays/blurb>
- [51] PyTorch, “PyTorch,” *Pytorch.org*, 2023. <https://pytorch.org/>
- [52] Wikipedia Contributors, “PyTorch,” *Wikipedia*, May 30, 2019. <https://en.wikipedia.org/wiki/PyTorch>
- [53] “PyTorch,” *ai.meta.com*. <https://ai.meta.com/tools/pytorch/>
- [54] “What is PyTorch?,” *NVIDIA Data Science Glossary*. <https://www.nvidia.com/en-us/glossary/pytorch/>
- [55] Pandas, “Python Data Analysis Library,” *Pydata.org*, 2018. <https://pandas.pydata.org/>
- [56] “pandas (software),” *Wikipedia*, Feb. 19, 2020. [https://en.wikipedia.org/wiki/Pandas_\(software\)](https://en.wikipedia.org/wiki/Pandas_(software))
- [57] “What is pandas Python?,” *NVIDIA Data Science Glossary*. <https://www.nvidia.com/en-us/glossary/pandas-python/>
- [58] “NumPy,” *numpy.org*. <https://numpy.org/about/>
- [59] Wikipedia Contributors, “NumPy,” *Wikipedia*, Jul. 26, 2019. <https://en.wikipedia.org/wiki/NumPy>
- [60] “What is NumPy?,” *NVIDIA Data Science Glossary*. <https://www.nvidia.com/en-us/glossary/numpy/>

- [61] Scikit-learn, “scikit-learn: machine learning in Python,” *Scikit-learn.org*, 2019. <https://scikit-learn.org/stable/>
- [62] Wikipedia Contributors, “scikit-learn,” *Wikipedia*, Mar. 19, 2019. <https://en.wikipedia.org/wiki/Scikit-learn>
- [63] “What is Scikit-learn?,” *NVIDIA Data Science Glossary*. <https://www.nvidia.com/en-us/glossary/scikit-learn/>
- [64] Matplotlib, “Matplotlib: Python plotting — Matplotlib 3.1.1 documentation,” *Matplotlib.org*, 2012. <https://matplotlib.org/>
- [65] Wikipedia Contributors, “Matplotlib,” *Wikipedia*, Nov. 21, 2019. <https://en.wikipedia.org/wiki/Matplotlib>
- [66] Microsoft, “Visual Studio Code,” *Visualstudio.com*, 2024. <https://code.visualstudio.com/>
- [67] Wikipedia Contributors, “Visual Studio Code,” *Wikipedia*, Mar. 21, 2019. https://en.wikipedia.org/wiki/Visual_Studio_Code
- [68] T. F. Authors, “Flower: A Friendly Federated Learning Framework,” *flower.ai*. <https://flower.ai/>
- [69] K. Majid, “Federated Learning With Flower - Kundroo Majid - Medium,” *Medium*, Sep. 21, 2023. <https://medium.com/@kundroomajid/federated-learning-with-flower-6b0614748c4d> (accessed Jul. 05, 2024).
- [70] M. G. Arivazhagan, V. Aggarwal, A. K. Singh, and S. Choudhary, “Federated Learning with Personalization Layers,” *arXiv:1912.00818 [cs, stat]*, Dec. 2019, Available: <https://arxiv.org/abs/1912.00818>
- [71] M. Chen, N. Shlezinger, H. V. Poor, Y. C. Eldar, and S. Cui, “Communication-efficient federated learning,” *Proceedings of the National Academy of Sciences*, vol. 118, no. 17, p. e2024789118, Apr. 2021, doi: <https://doi.org/10.1073/pnas.2024789118>.
- [72] J. Kirkpatrick *et al.*, “Overcoming catastrophic forgetting in neural networks,” *arXiv.org*, 2016. <https://arxiv.org/abs/1612.00796>
- [73] Daniel Yue Zhang, Z. Kou, and D. Wang, “FairFL: A Fair Federated Learning Approach to Reducing Demographic Bias in Privacy-Sensitive Classification Models,” Dec. 2020, doi: <https://doi.org/10.1109/bigdata50022.2020.9378043>.

- [74] K. Bonawitz *et al.*, “Towards Federated Learning at Scale: System Design,” *Proceedings of Machine Learning and Systems*, vol. 1, pp. 374–388, Apr. 2019, Available: https://proceedings.mlsys.org/paper_files/paper/2019/hash/7b770da633baf74895be22a8807f1a8f-Abstract.html
- [75] *Whimsical*. <https://whimsical.com/login>
- [76] “Root mean square deviation,” *Wikipedia*, May 03, 2024. https://en.wikipedia.org/wiki/Root_mean_square_deviation
- [77] “Mean Bias Error - an overview | ScienceDirect Topics,” *www.sciencedirect.com*. <https://www.sciencedirect.com/topics/engineering/mean-bias-error>
- [78] Wikipedia Contributors, “Coefficient of determination,” *Wikipedia*, Feb. 27, 2019. https://en.wikipedia.org/wiki/Coefficient_of_determination
- [79] Available: https://www.researchgate.net/figure/An-example-of-LSTM-cell-structure_fig2_376375462
- [80] Available: <https://www.researchgate.net/profile/Ola-Surakhi-3/publication/355337314/figure/fig4/AS:1079408471343113@1634362442234/Sequential-Long-Short-Term-Memory-LSTM-architecture.ppm>
- [81] Arash Moradzadeh, Hamed Moayyed, Behnam Mohammadi-Ivatloo, A. Pedro Aguiar, J. M. Guerrero, and Zulkurnain Abdul-Malek, “Generalized global solar radiation forecasting model via cyber-secure deep federated learning,” *Environmental Science and Pollution Research*, Oct. 2023, doi: <https://doi.org/10.1007/s11356-023-30224-1>.
- [82] Available: https://www.researchgate.net/figure/The-framework-of-Federated-Learning-Graphical-illustration-of-the-working-principle-of_fig1_367191647
- [83] E. Sarmas, E. Spiliotis, E. Stamatopoulos, V. Marinakis, and H. Doukas, “Shortterm photovoltaic power forecasting using metalearning and numerical weather prediction independent Long ShortTerm Memory models,” *Renewable Energy*, vol. 216, p. 118997, 2023, doi: <https://doi.org/10.1016/j.renene.2023.118997>.
- [84] L. Ilias, E. Sarmas, V. Marinakis, D. Askounis, and H. Doukas, “Unsupervised domain adaptation methods for photovoltaic power forecasting,” *Applied Soft Computing*, vol. 149, p. 110979, 2023, doi: <https://doi.org/10.1016/j.asoc.2023.110979>.

- [85] E. Sarmas, E. Spiliotis, N. Dimitropoulos, V. Marinakis, and H. Doukas, “Estimating the Energy Savings of Energy Efficiency Actions with Ensemble Machine Learning Models,” *Applied Sciences*, vol. 13, no. 4, p. 2749, Jan. 2023, doi: <https://doi.org/10.3390/app13042749>.
- [86] E. Sarmas, A. Forouli, V. Marinakis, and H. Doukas, “Baseline energy modeling for improved measurement and verification through the use of ensemble artificial intelligence models,” *Information Sciences*, vol. 654, p. 119879, 2024, doi: <https://doi.org/10.1016/j.ins.2023.119879>.